



Universidade de Brasília – UnB
Faculdade UnB Gama – FGA
Engenharia Aeroespacial

Sistema para Monitoramento dos Campos de Murundus do Distrito Federal Mediante Sensoriamento Remoto

Autor: Luiz Fernando Rocha de Carvalho
Orientador: Giancarlo Santilli, Dr

Brasília, DF
2018



Luiz Fernando Rocha de Carvalho

Sistema para Monitoramento dos Campos de Murundus do Distrito Federal Mediante Sensoriamento Remoto

Monografia submetida ao curso de graduação
em Engenharia Aeroespacial da Universidade
de Brasília, como requisito parcial para ob-
tenção do Título de Bacharel em Engenharia
Aeroespacial.

Universidade de Brasília – UnB

Faculdade UnB Gama – FGA

Orientador: Giancarlo Santilli, Dr

Brasília, DF

2018

Luiz Fernando Rocha de Carvalho

Sistema para Monitoramento dos Campos de Murundus do Distrito Federal
Mediante Sensoriamento Remoto/ Luiz Fernando Rocha de Carvalho. – Brasília,
DF, 2018-

109 p. : il. (algumas color.) ; 30 cm.

Orientador: Giancarlo Santilli, Dr

Trabalho de Conclusão de Curso – Universidade de Brasília – UnB
Faculdade UnB Gama – FGA , 2018.

1. Campos de Murundus. 2. Sensoriamento Remoto. I. Giancarlo Santilli, Dr.
II. Universidade de Brasília. III. Faculdade UnB Gama. IV. Sistema para Monito-
ramento dos Campos de Murundus do Distrito Federal Mediante Sensoriamento
Remoto

CDU 02:141:005.6

Luiz Fernando Rocha de Carvalho

Sistema para Monitoramento dos Campos de Murundus do Distrito Federal Mediante Sensoriamento Remoto

Monografia submetida ao curso de graduação
em Engenharia Aeroespacial da Universidade
de Brasília, como requisito parcial para ob-
tenção do Título de Bacharel em Engenharia
Aeroespacial.

Trabalho aprovado. Brasília, DF, 28 de Março de 2018 – Data da aprovação do
trabalho:

Giancarlo Santilli, Dr
Orientador

Cristian Vendittozzi, Dr
Convidado 1

Marcus Vinícius Chaffim Costa, Dr
Convidado 2

Brasília, DF
2018

*Este trabalho é dedicado à todos envolvidos em minha formação acadêmica. Dentre eles
estão meus amigos, familiares e professores.*

*Dedico esse trabalho principalmente a minha família que me deu todo o suporte e apoio
necessário para a realização dos meus sonhos.*

Resumo

O Cerrado é o bioma principal do Distrito Federal (DF) ocupando uma área equivalente a 23% do território nacional. Tal bioma é único e possui feições peculiares que, por meio da urbanização e expansão imobiliária de Brasília, podem estar submetidas a graves degradações. Exemplo de feições peculiares encontradas no Cerrado são os Campos de Murundus. Os Campos de Murundus são microrrelevos, de formato circular ou elíptico, com dimensões variáveis. Eles têm grande relevância para o abastecimento hídrico de rios e nascentes já que os Murundus funcionam como reservatórios naturais de água. Por sua grande importância hídrica e rica biodiversidade, os Campos de Murundus são caracterizados como Áreas de Preservação Permanente no território do DF desde o ano de 2014. Portanto, se faz necessário um sistema para monitorar o estado de saúde desses microrrelevos.

O devido trabalho vem para sugerir um sistema de monitoramento dos Campos de Murundus por meio de sensoriamento remoto. O sistema foi inteiramente desenvolvido em *Matlab* com o auxílio da plataforma *GUIDE*. A plataforma desenvolvida é chamada de EcoTool e suporta tanto dados Landsat 8 quanto CBERS 4. A partir desses dados, três índices de vegetação são gerados automaticamente, são eles: NDVI, NDWI e SAVI. Com os índices gerados é possível acompanhar o estado de saúde dessas áreas durante as estações do ano. Utilizando-se da ferramenta EcoTool, foi notado que todos os índices acompanham a quantidade de chuva do Distrito Federal. Como a quantidade de chuva do DF tem um comportamento sazonal, todos os índices também apresentaram tal comportamento. Além disso, notou-se que, durante a estação seca de Brasília (entre Junho e Outubro), Campos de Murundus não preservados apresentaram um pico anormal nos índices NDVI e NDWI. Por fim, foi percebido que o SAVI não traz informações adicionais ao sistema de monitoramento. Tal índice apresentou comportamento muito semelhante ao NDVI para os Campos de Murundus do DF, portanto, apenas o NDVI e o NDWI foram utilizados para monitoramento desse campos.

Palavras-chaves: Campos de Murundus, Sensoriamento Remoto, Processamento Digital de Imagens.

Abstract

The Cerrado is the main biome of the Federal District (DF) occupying an area equivalent to 23% of the Brazilian national territory. Such a biome is unique and has peculiar features that, through urbanization of Brasilia, could have been subject to serious degradation. Example of peculiar features found in the Cerrado are the Murundus Fields. Murundus Fields are very specific mounds, of circular or elliptical shape, with variable dimensions. This mounds, also compared to the Mima Mounds, have great relevance for the water supply of rivers since the Murundus function as natural reservoirs of water. Because of its great hydrological importance and biodiversity, Murundus Fields are denominated as Permanent Preservation Areas in the territory of the Federal District since the year 2014. Therefore, a system for monitoring these areas is necessary not only to avoid degradation by people but also to monitor the health status of these mounds.

This bachelor-thesis comes to suggest a system for monitoring these areas by remote sensing. The system was fully developed in *Matlab* language using its *GUIDE* platform. As a result, a platform called EcoTool was created supporting not only Landsat 8 data but also CBERS 4 data. Using these data, three vegetation indexes are automatically generated, which are: NDVI, NDWI, and SAVI. These three indexes allow us to check the natural behavior and health status of the Murundus Fields during the year. By using EcoTool, it has been noticed that all three indexes are very linked to the amount of rainfall during the year in the DF. This quantity of rainfall during the year has a seasonal behavior, which has been the behavior noticed for all three indexes. Moreover, during the dry season of DF (from June to October), all Murundus Fields which are not preserved have presented an anomaly on their NDVI and NDWI indexes. Furthermore, the SAVI index showed to be irrelevant for monitoring Murundus fields in the territory of DF. This index has a behavior very similar to NDVI's behavior. For this reason, only NDVI and NDWI were used for monitoring the Murundus fields.

Key-words: Murundus Fields, Remote Sensing, Image Processing.

Lista de ilustrações

Figura 2.1.1–Campo de Murundus do Gama - Distrito Federal	20
Figura 2.1.2–Área Variável de Afluência, processo de geração do escoamento direto de acordo com a variação pluviométrica. Adaptado de (HEWLETT; HIBBERT, 1963)	22
Figura 2.2.1–Imagem de SR, LandSat 8	26
Figura 2.2.2–Imagem Digital de 8 Bits	27
Figura 2.2.3–Imagem do Satélite CBERS 4 de Brasília (Lago Sul), Resolução de 5 m	28
Figura 2.2.4–Imagem do Satélite CBERS 4 de Brasília (Lago Sul), Resolução de 20 m	28
Figura 2.2.5–Imagem Landsat8, 8 Bits	29
Figura 2.2.6–Imagem Landsat8, 3 bits	30
Figura 2.2.7–NDVI de Brasília, Satélite LandSat 8 (OLI)	31
Figura 2.2.8–SAVI de Brasília, Satélite LandSat 8 (OLI)	33
Figura 2.2.9–NDWI de Brasília, Satélite LandSat 8 (OLI)	34
Figura 2.2.10–Missões Landsat (Fonte: https://landsat.gsfc.nasa.gov/a-landsat-timeline/)	35
Figura 2.2.11–Sensores Landsat 7 e 8 (Fonte: https://landsat.gsfc.nasa.gov/landsat-data-continuity-mission/)	37
Figura 2.2.12–CBERS 1 e 2, Características (Fonte: www.cbers.inpe.br (Adaptado)) .	38
Figura 2.2.13–CBERS 2B (Fonte: www.cbers.inpe.br (Adaptado))	40
Figura 2.2.14–CBERS 3 e 4 (Fonte: www.cbers.inpe.br (Adaptado))	41
Figura 3.0.1–EcoTool	43
Figura 3.0.2–Processo Completo de Monitoramento por Sensoriamento Remoto . . .	44
Figura 3.0.3–Sistema de Monitoramento Proposto	45
Figura 3.1.1–Site INPE	46
Figura 3.1.2–Parâmetros Básicos, INPE	46
Figura 3.1.3–Municípios, INPE	47
Figura 3.1.4–Imagens Selecionadas pelo Servidor, INPE	47
Figura 3.2.1–Georreferenciamento	49
Figura 3.3.1–Ortofotos	50
Figura 3.4.1–(a)Fazenda Aguá Limpa, (b) Campo de Murundus	51
Figura 3.4.2–Campo de Murundus - FGA, (Fonte: Google Earth)	51
Figura 3.4.3–Campo de Murundus - Samambaia, (Fonte: Google Earth)	52
Figura 3.4.4–Floresta Nacional, (Fonte: Google Earth)	52
Figura 3.4.5–Campo de Murundus - Floresta Nacional, (Fonte: Google Earth)	53
Figura 3.4.6–Parque Nacional, (Fonte: Google Earth)	53
Figura 3.4.7–Campo de Murundus- Parque Nacional, (Fonte: Google Earth)	54
Figura 3.4.8–Chapada Imperial, (Fonte: Google Earth)	54

Figura 3.5.1–Registro Automático de Imagem	55
Figura 3.7.1–Fmask algoritmo - Nuvens e Sombra de Nuvens	58
Figura 3.7.2–algoritmo da Máscara Banda BQA	59
Figura 3.7.3–Construção de Máscara - Landsat 8/Oli	60
Figura 3.7.4–RGB - Cbers 4 / MUX	62
Figura 3.7.5–HOT - Cbers 4 / MUX	62
Figura 3.7.6–SOT - Cbers 4 / MUX	63
Figura 3.7.7–CSVI - Cbers 4 / MUX	64
Figura 3.7.8–WI - Cbers 4 / MUX	65
Figura 3.7.9–Máscara de Nuvens - Cbers 4 / MUX	66
Figura 3.7.10–Máscara de Sombras - Cbers 4 / MUX	67
Figura 3.7.11–Construção de Máscara - Landsat 8/Oli	68
Figura 3.8.1–FAL - 2015 a 2017	69
Figura 3.8.2–FGA - 2015 a 2017	70
Figura 3.8.3–Samambaia - 2015 a 2017	70
Figura 3.8.4–Floresta Nacional - 2015 a 2017	71
Figura 3.8.5–Parque Nacional - 2015 a 2017	71
Figura 3.8.6–Chapada Imperial - 2015 a 2017	72
Figura 4.0.1–Precipitação Média de Chuva de Brasília	74
Figura 4.0.2–NDVI e NDWI: OLI - 2015 a 2017	75
Figura 4.0.3–NDVI e NDWI: MUX - 2015 a 2017	76
Figura A.0.1–Rotina <i>GET_DATA_FROM_LINK.m</i>	86
Figura B.0.1–EcoTool	87
Figura B.1.1–Criando Novo Projeto	88
Figura B.1.2–Nome do Novo Projeto	88
Figura B.1.3–Diretório do Novo Projeto	89
Figura B.1.4–Salvando o Novo Projeto	89
Figura B.2.1–Importando Dados ao Projeto	90
Figura B.2.2–Selecionando Plataforma	90
Figura B.2.3–Selecionando Imagens	91
Figura B.2.4–Copiar ou Mover	91
Figura B.2.5–Carregando Imagens ao Projeto	92
Figura B.2.6–Carregando Concluído	92
Figura B.3.1–Criando Base de Dados	93
Figura B.3.2–Nome Base de Dados	93
Figura B.3.3–Base de Dados Criada	94
Figura B.4.1–Seleção de Ortofoto	95
Figura B.4.2–Interface para Seleção de Ortofoto	95
Figura B.4.3–Importando Imagens - Passo 1	96

Figura B.4.4Importando Imagens - Passo 2	96
Figura B.4.5Importando Imagens	97
Figura B.4.6Imagens Carregadas	97
Figura B.4.7Área de Interesse - Passo 1	98
Figura B.4.8Área de Interesse - Passo 2	98
Figura B.4.9Visualizando a Área de Interesse	99
Figura B.4.10Salvando Pacote de Ortofotos	99
Figura B.4.11Confirmação para Salvar Pacote de Ortofotos	100
Figura B.4.12Ortofoto	100
Figura B.5.1Ortofoto	101
Figura B.5.2Interface para Seleção de Região de Interesse	102
Figura B.5.3Banco de Dados	102
Figura B.5.4Plataforma	103
Figura B.5.5Ortofoto	103
Figura B.5.6Run	104
Figura B.5.7Seleção de área de interesse	104
Figura B.5.8Salvando ROI	105
Figura B.5.9Confirmação de informações	105
Figura B.6.1Compilação Automática das Imagens	106
Figura B.6.2Compilação Automática: Banco de Dados	106
Figura B.6.3Compilação Automática: Instrumento	107
Figura B.6.4Compilação Automática: Barra de Acompanhamento	107
Figura B.6.5Imagens aceitas pelo algoritmo automático	108
Figura B.7.1Resultados	108
Figura B.7.2Interface de Resultados	109
Figura B.7.3Interface de Resultados	109

Lista de tabelas

Tabela 2.2.1-Sensores utilizados nas missões Landsat 1 a 7	36
Tabela 2.2.2-Sensores Landsat 8	37
Tabela 2.2.3-WFI (Fonte: www.cbers.inpe.br)	38
Tabela 2.2.4-HR CCD (Fonte: www.cbers.inpe.br)	39
Tabela 2.2.5-IRMSS (Fonte: www.cbers.inpe.br)	39
Tabela 2.2.6-HRC (Fonte: www.cbers.inpe.br)	40
Tabela 2.2.7-Câmeras CBERS 3 e 4 (Fonte: www.cbers.inpe.br)	42
Tabela 2.2.8-Câmeras CBERS 3 e 4 (Fonte: www.cbers.inpe.br)	42
Tabela 3.6.1-Calibração Radiométrica CBERS4/MUX (Fonte: Pinto (2016))	56
Tabela 3.6.2-Calibração Radiométrica Landsat8/OLI (Fonte: USGS (2017))	57
Tabela 3.7.1-Limiar: Máscara de Nuvens - CBERS4/MUX	65
Tabela 3.7.2-Limiar: Máscara de Sombras - CBERS4/MUX	66
Tabela 4.0.1-Valores de Referência para Murundus Saudáveis	77
Tabela 4.0.2-Período de Estresse Hídrico dos Murundus do Distrito Federal	78

Lista de abreviaturas e siglas

APP	Áreas de Preservação Permanente
AVA	Área Variável de Influência
CBERS	China-Brazil Earth Resources Satellite (Satélite Sino-Brasileiro de Recursos Terrestres)
CSVI	Combined Soil-Vegetation Index (Índice Combinado de Vegetação e Solo)
DF	Distrito Federal
ERTS	Earth Resources Technology Satellite (Satélite de Tecnologia de Recursos Terrestres)
ETM	Enhanced Thematic Mapper (Mapeador Temático Aprimorado)
ETM+	Enhanced Thematic Mapper Plus (Mapeador Temático Aprimorado Plus)
FAL	Fazenda Água Limpa
FGA	Faculdade Gama - UnB
<i>HOT</i>	Haze Optimized Transformation (Transformação Otimizada de Neblina)
HRC	High Resolution Camera (Câmera de Alta Resolução)
HR CCD	High Resolution Charge Coupled Device (Dispositivo Acoplado de Carga de Alta Resolução)
INPE	Instituto Nacional de Pesquisas Espaciais
IRMSS	Infrared Multi Spectral Scanner (Scanner Infravermelho Multiespectral)
IRS	Imageador Multiespectral e Termal
MSS	Multispectral Scanner System (Sistema de Scanner Multiespectral)
MUX	Câmera Multiespectral Regular
NC	Nível de Cinza

NDVI	Normalized Difference Vegetation Index (Índice de Vegetação da Diferença Normalizada)
NDWI	Normalized Difference Water Index (Índice de Diferença Normalizada da Água)
NIR	Near Infrared (Infravermelho Próximo)
OLI	Operational Land Imager (Imageador Operacional de Terreno)
PAN	Câmera Pancromática e Multiespectral
RBV	Return Beam Vidicon
REM	Radiação Eletromagnética
SAVI	Soil Adjusted Vegetation Index (Índice de Vegetação Ajustado ao Solo)
<i>SOT</i>	Shadow Optimized Transformation (Transformação Otimizada de Sombra)
SR	Sensoriamento Remoto
SURF	Speed-Up Robust Features
SWIR	Short Wave Infrared (Infravermelho de Ondas Curtas)
TIR	Thermal Infrared (Infravermelho Termal)
TIRS	Thermal Infrared Sensor (Sensor Infravermelho Termal)
TM	Thematic Mapper (Mapeador Temático)
UnB	Universidade de Brasília
VI	Vegetation Indices (Índices de Vegetação)
WFI	Wide Field Imager (Imageador de Campo Largo)
WI	Whiteness Index (Índice de Brancura)

Lista de símbolos

d	Distância Sol-Terra
$ESUN_{\lambda}$	Irradiância Solar Exoatmosférica Média no Topo da Atmosfera
L_{λ}	Radiância Espectral
ρ	Reflectância
$\rho_{\lambda,Toa}$	Reflectância no Topo da Atmosfera
ρ_{Green}	Reflectância da banda espectral do verde
ρ_{NIR}	Reflectância da banda do infravermelho próximo
ρ_{Red}	Reflectância da banda do vermelho
θ	Ângulo Zenital Solar

Sumário

1	INTRODUÇÃO	17
	Introdução	17
1.1	Justificativa	17
1.2	Objetivos	18
1.2.1	Objetivo Geral	18
1.2.2	Objetivo Específico	18
2	FUNDAMENTAÇÃO TEÓRICA	19
2.1	Campos de Murundus	19
2.1.1	Dinâmica Hídrica	20
2.1.1.1	Modelo de Horton, 1933: Teoria da infiltração do escoamento superficial	20
2.1.1.2	Modelo de Hewlett e Hibbert: <i>Variable Source Areas</i>	21
2.1.2	Formação / Natureza dos Murundus do Cerrado	23
2.1.2.1	Hipótese Biológica	23
2.1.2.2	Hipótese Geomorfológica	23
2.1.2.3	Porquê os Murundus são APP?	24
2.2	Sensoriamento Remoto	26
2.2.1	Imagens Digitais	27
2.2.2	Resolução	27
2.2.2.1	Resolução Espacial	27
2.2.2.2	Resolução Espectral	29
2.2.2.3	Resolução Radiométrica	29
2.2.2.4	Resolução Temporal	30
2.2.3	Índices de Vegetação	30
2.2.3.1	NDVI	31
2.2.3.2	SAVI	32
2.2.3.3	NDWI	33
2.2.4	Plataformas	35
2.2.4.1	LandSat	35
2.2.4.2	CBERS	38
3	METODOLOGIA	43
3.1	Download de Imagens	45
3.2	Correção Geométrica	48
3.3	Seleção de Imagem de Referência	49

3.4	Seleção das Áreas de Estudo	50
3.4.1	Fazenda Aguá Limpa – UnB (FAL)	50
3.4.2	Campus Gama da Universidade de Brasília (FGA)	51
3.4.3	Samambaia	52
3.4.4	Floresta Nacional de Brasília	52
3.4.5	Parque Nacional de Brasília	53
3.4.6	Chapada Imperial	54
3.5	Registro de Imagem	55
3.6	Calibração Radiométrica	56
3.7	Máscaras	57
3.7.1	Landsat8/OLI	57
3.7.2	CBERS 4/ MUX	61
3.8	Geração de Índices	69
4	RESULTADOS E DISCUSSÃO	73
5	CONCLUSÕES	80
	REFERÊNCIAS	82
	APÊNDICES	85
	APÊNDICE A – ROTINA <i>GET_DATA_FROM_LINK.M</i>	86
	APÊNDICE B – ECOTOOL	87
B.1	Criação de Projeto	88
B.2	Importação de Dados ao Projeto	90
B.3	Criação de Banco de Dados	92
B.4	Seleção de Imagem de Referência - Ortofoto	94
B.5	Seleção de Região de Interesse - ROI	101
B.6	Compilação das Imagens	106
B.7	Resultados	108

1 Introdução

Com a urbanização de Brasília muitas áreas do Cerrado foram danificadas, áreas essas que poderiam ser de grande importância para captação de recursos hídricos e abastecimento de rios, como os Campos de Murundus. De acordo com a instrução N° 39 de 21 de Fevereiro de 2014, que caracteriza os Campos de Murundus como Áreas de Preservação Permanente (APP's) para o território do Distrito Federal, os Murundus são classificados como elevações arredondas ou ovais com dimensões variadas, desde poucos centímetros a 2 metros e cujo diâmetro pode alcançar até 10 metros. A origem dessas elevações é suportada por duas teses distintas, porém não excludentes: uma biológica e outra geomorfológica. A primeira hipótese diz que os Murundus surgiram a partir de atividades de térmitas, como os cupins. Assim, os Murundus seriam formados por sucessivas colonizações de espécies de cupins, algumas mais tolerantes a solos úmidos que as outras (MATHEWS, 1977). Já a segunda hipótese diz que os Murundus surgiram por fatores geomorfológicos, como a erosão diferencial e o acúmulo de sedimentos. Seguindo esta tese, os Murundus teriam origem da erosão diferencial, portanto seriam relevos residuais resultantes da ação erosiva diferencial provocada por escoamento superficial (SILVA et al., 2010).

1.1 Justificativa

Por ser uma APP de grande valor para captação de recursos hídricos, e por sua rica biodiversidade, é justificável a elaboração de um sistema de monitoramento para essas áreas. O devido trabalho vem com o propósito de sugerir uma ferramenta de monitoramento dos Campos de Murundus do Distrito Federal. A ferramenta, chamada de EcoTool, foi inteiramente desenvolvido em *Matlab* com o auxílio da plataforma *GUIDE* e suporta tanto dados Landsat 8 quanto CBERS 4. Por meio desses dados, o sistema monitora o estado de saúde das áreas selecionadas utilizando modelos matemáticos de índices de vegetação, tais como o NDVI, SAVI e NDWI. Ecotool é uma ferramenta robusta que pode tanto monitorar campos de murundus quanto outras coberturas vegetais, tais como plantações e florestas.

O primeiro índice (NDVI) é denominado Índice de Vegetação da Diferença Normalizada. A partir dele pode-se determinar a porcentagem de cobertura do solo, bem como o estado de saúde da vegetação presente. Já o Índice de Vegetação Ajustado ao Solo (SAVI), também informa sobre a saúde da vegetação, porém não é tão sensível às diferentes coberturas de vegetação como o NDVI. Por sua vez, o NDWI, menos sensível a efeitos atmosféricos que os outros índices, representa o índice de água. Com esse índice é possível adquirir informações sobre a água presente nos diferentes tipos de vegetação.

1.2 Objetivos

1.2.1 Objetivo Geral

Esse trabalho tem como objetivo geral sugerir um sistema para monitoramento dos Campos de Murundus do Distrito Federal por meio de sensoriamento remoto. Uma plataforma gráfica chamada de *EcoTool* foi desenvolvida inteiramente em *Matlab*, com o auxílio da plataforma *GUIDE*, para testar o sistema proposto. *Ecotool* ainda está em fase de testes e estará disponível para a comunidade em Julho de 2018.

1.2.2 Objetivo Específico

O devido trabalho tem com objetivo específico demonstrar que imagens Landsat 8 e CBERS 4 podem ser utilizadas para monitoramento ambiental. Por meio de processamento digital de imagens é possível extrair informações das áreas de interesse, tais como: cobertura vegetal do solo, estado de saúde da vegetação, quantidade de água acumulada pela vegetação e monitorar áreas desmatadas.

2 Fundamentação Teórica

2.1 Campos de Murundus

O Cerrado é o bioma principal do Distrito Federal, e o segundo maior do Brasil, ocupando uma área maior que 23% do território nacional. Tal bioma é composto principalmente por formações savânicas e outras formações específicas do Cerrado. Durante a urbanização e expansão imobiliária do Distrito Federal muitas formações do cerrado foram degradadas, ou até mesmo completamente destruídas, por exemplo, os Campos de Murundus.

Os Murundus, comparados aos *Mima Mounds*, podem ser descritos como microrrelevos, de formato circular ou elíptico, com dimensões variáveis. Seu diâmetro pode variar entre 3 a 50 m e sua altura pode chegar até 2 metros. Para Araújo Neto os Murundus são elevações semicirculares, arredondadas ou ovais, com dimensões médias de 10 metros de comprimento, 70 centímetros de altura e 6 metros de largura (NETO, 1981). A área plana e os Murundus menores são cobertos por vegetação campestre e os maiores, por vegetação lenhosa do Cerrado (NETO et al., 1986; OLIVEIRA-FILHO, 1992).

Já para Guerra (1993), o murundu é o “termo usado no Pantanal mato-grossense para pequenas elevações circulares, com mais ou menos um metro de altura, por quatro a seis metros de diâmetro, tratando-se, possivelmente, de dunas incipientes. Os Murundus situam-se na periferia das baías ou nas encostas das cordilheira”.

De acordo com a lei N° 5344 de 19 de Maio de 2014, os Campos de Murundus do Distrito Federal são definidos por um ecossistema que integra a fitofisionomia Parque de Cerrado, caracterizado pela presença de hidromorfismo, gramíneas, herbáceas, arbustos ou árvores agrupadas em pequenas elevações do terreno, em algumas vezes, imperceptíveis e, em outras, com muito destaque.

Para o devido trabalho, os Murundus estudados tiveram um diâmetro entre 5 a 10 m, e altura que pode chegar até 70 cm. A Fig. 2.1.1 representa o Campo de Murundus da Faculdade Gama do Universidade de Brasília (FGA/UnB). Como pode ser observado, os Murundus da Fig. 2.1.1 possuem esse formato circular ou elíptico citado por (NETO, 1981).



Figura 2.1.1 – Campo de Murundus do Gama - Distrito Federal

Os Campos de Murundus possuem uma dinâmica hídrica muito peculiar. O nível do lençol freático de cada Murundu varia sazonalmente de acordo com o regime pluviométrico. Geralmente, durante o período chuvoso, os Murundus armazenam água em seus lençóis freáticos até ultrapassar a capacidade de infiltração do solo. Se essa capacidade for alcançada, o murundu será inundado, e não apresentará vegetação lenhosa como árvores ou arbustos, mas poderá ser coberto por vegetação campestre. Entretanto, caso o lençol freático não transborde, o murundu poderá apresentar vegetação lenhosa.

2.1.1 Dinâmica Hídrica

2.1.1.1 Modelo de Horton, 1933: Teoria da infiltração do escoamento superficial

As pesquisas de Horton são consideradas pioneiras no que se refere a hidrologia de bacias de drenagem. Nesse modelo clássico, Horton acreditava que o escoamento direto era produzido apenas pelo escoamento superficial, que ocorria toda vez que capacidade de infiltração do solo era excedida ([HORTON, 1933](#)). Assim, durante as chuvas, ao atingir a capacidade de infiltração, ocorreria o escoamento superficial que provinha de todas as partes da microbacia. Tal escoamento foi posteriormente chamado de escoamento superficial Hortoniano em sua homenagem. Entretanto, quando a capacidade de infiltração não era atingida, a água infiltrava ao solo, abastecia o lençol freático para depois chegar ao rio na forma de escoamento de base ([SANTOS et al., 2009](#)).

Posteriormente, foi visto que o modelo apontado por Horton era dominante para poucos casos. Tal modelo era considerado válido em regiões áridas ou semiáridas, onde a ocorrência de vegetação era deficiente, e em áreas que sofreram perturbações antrópicas, como as áreas urbanas, já que a superfície do solo é quase impermeável. Uma sequência de trabalhos posteriores mostrou que o escoamento superficial provém de uma pequena parte da microbacia, contrariando a ideia anterior de Horton que afirmava que o escoamento

superficial provinha de todas as partes da microbacia (HEWLETT; HIBBERT, 1963).

2.1.1.2 Modelo de Hewlett e Hibbert: *Variable Source Areas*

Hewlett e Hibbert desenvolveram o conceito de Área Variável de Influência, (do inglês, *Variable Source Area*) (HEWLETT; HIBBERT, 1963). Em seu trabalho, os autores descobriram que a saturação do solo é resultado da dinâmica do nível freático.

A ideia de Área Variável de Influência (AVA) afirma que o processo de escoamento superficial não ocorre em todas as partes de uma bacia hidrográfica, portanto apenas algumas partes da bacia contribuiriam efetivamente para o deflúvio (escoamento direto). Hewlett e Hibbert, estudando microbacias com uma densa cobertura vegetal, foram contrários às ideias propostas por Horton ao dizer que o escoamento superficial por saturação ocorreria em pequenas partes de uma bacia (HEWLETT; HIBBERT, 1963). De acordo com os autores, as áreas onde ocorriam escoamento superficial poderiam sofrer expansões e contrações sazonais, dependendo da intensidade de chuva, profundidade de solo e umidade inicial.

Hewlett e Hibbert chegaram a conclusão de que, para uma bacia de clima úmido e com alto índice de vegetação, boa parte da água da chuva infiltrava o solo da bacia e alimentava os canais de curso da água por canais subterrâneos e subsuperficiais (HEWLETT; HIBBERT, 1963). Assim que o escoamento subsuperficial saturasse a capacidade do solo de transportá-lo ocorria a elevação do nível da água do solo, ocorrendo então o escoamento de retorno. Tal processo de escoamento de retorno é de extrema importância para o processo de expansão das AVA's, já que ele está fortemente relacionado com o escoamento superficial. A partir do momento em que o volume de chuva diminuísse, essas áreas de saturação iriam se contrair, por isso utiliza-se a nomenclatura “Área Variável”.

A Fig. 2.1.2 ilustra o processo dinâmico de expansões e contrações das AVA's de acordo com o volume pluviométrico. No momento inicial ($t = 0$, sem chuva), as AVA's ocupam uma área muito pequena. Com o aumento do volume das chuvas, as áreas de saturação vão aumentando em número e área, chegando a uma expansão máxima no momento em que a quantidade de chuva atinge seu máximo.




Figura 2.1.2 – Área Variável de Afluência, processo de geração do escoamento direto de acordo com a variação pluviométrica. Adaptado de (HEWLETT; HIBBERT, 1963)

Baptista, Corrêa e Santos (2013) relacionam em seu trabalho o comportamento hídrico dos Murundus com o comportamento das *Variable Source Areas*. Baseado no trabalho anterior de NETO e BAPTISTA (1995), os autores utilizam de alguns fatores, como a sazonalidade do lençol freático dos Murundus, para relacionar a dinâmica hídrica dos Murundus com o modelo de Hewlett e Hibbert. Em período chuvosos, as águas escoam em superfície por causa do transbordamento do lençol freático dos Campos de Murundus do Distrito Federal. Fato esse que está ligado à elevação do nível da água do solo, devido à saturação escoamento subsuperficial, citada no trabalho de Hewlett e Hibbert. Já em período de estiagem, ocorre o rebaixamento do nível do lençol, e o campo deixa de ser uma área de “produção” de água, ocorrendo uma contração semelhante a que ocorre nas AVA’s quando o volume de chuva diminui (BAPTISTA; CORRÊA; SANTOS, 2013).

Castro Júnior também estudou a dinâmica das águas nos Campos de Murundus. Estudando Campos de Murundus do Planalto do Parecis, o autor também notou a saturação, ou supersaturação em água, dos Murundus durante alguns meses do ano (JÚNIOR, 2002). Tal saturação fazia com que o lençol freático transbordasse à superfície do solo, assim ocorreria o fluxo superficial Hortoniano para abastecimento das nascentes.

Ainda em seu trabalho, Castro Júnior ressalta que durante o período seco, com aproximadamente 6 meses de duração, os Murundus se comportam como reservatórios naturais, fornecendo lentamente a água armazenada em solo às nascentes e cursos (JÚNIOR, 2002). Essa dinâmica hídrica, durante o período seco, suporta o modelo de *Variable Source*

Áreas citadas por Batista ([BAPTISTA; CORRÊA; SANTOS, 2013](#)). Assim, durante períodos de estiagem, a maior parte do abastecimento dos rios, por meio dos Campos de Murundus, seria controlada pelas forças absorptivas da matriz do solo e não pelo fluxo superficial.

2.1.2 Formação / Natureza dos Murundus do Cerrado

A origem dos Murundus é um tema muito discutido e ainda não se chegou a um consenso. Atualmente existem duas hipóteses, não excludentes, que explicam a origem dos Murundus: uma biológica e outra geomorfológica.

2.1.2.1 Hipótese Biológica

A primeira hipótese, relacionada com a formação dos Murundus dos Campos brejosos de encosta, e sustentada por [Oliveira-Filho \(1992\)](#), diz que os Murundus surgiram por agentes biológicos. Essa hipótese afirma que atividades de térmitas, como os cupins, deram origem aos Murundus. Estudando Campos de Murundus brejosos de encosta, [Mathews \(1977\)](#) esquematizou a sequência de formação dos Murundus em três etapas.

Primeiramente, uma espécie de cupim mais tolerante a solos úmidos, como a *Armitermes cerradoensis*, instala-se no campo durante o período seco, edificando um pequeno ninho na base do tufo de uma gramínea.

Posteriormente, na segunda etapa, essa espécie de cupim morre e o cupinzeiro pioneiro é então destruído parcialmente. O monte de terra restante do cupinzeiro morto continua a ser ampliado nas estações úmidas por minhocas e outras espécies de cupins, podendo ser colonizado ou não por plantas menos tolerantes aos encharcamentos.

Por fim, na terceira etapa, uma terceira espécie de cupim, como a *Cornitermes snyderi*, se instala nos montes de terra maiores. Durante estações mais prolongadas de seca, esses cupins constroem termiteiros bem mais volumosos e pouco tolerantes às inundações sazonais, exigindo uma plataforma maior e mais seca. Daí em diante o cupinzeiro é atacado por predadores e reconstruído pela mesma espécie de térmita, ou por novas espécies, sucessivamente, formando montes de terra cada vez maiores ao redor do cupinzeiro pioneiro ([MATHEWS, 1977](#)). Com isso, a morte das colônias, que frequentemente leva a ocupação dos ninhos por formigas, ou a sua destruição parcial por animais termitófagos expõe o material dos cupinzeiros à erosão e desestruturação, facilitando sua colonização pelas plantas ([ANTUNES et al., 2012](#)).

2.1.2.2 Hipótese Geomorfológica

A segunda hipótese de origem dos Murundus afirma que eles se formaram devido a fatores geomorfológicos, como a erosão diferencial e acúmulo de sedimentos. Para Furley, a

erosão diferencial do solo é o fator principal para a formação dos Murundus (NETO et al., 1986). Seguindo essa mesma linha de pensamento, Silva et al. (2010) comprova, através de análise química, física, florística e de isótopos de carbono do solo, que os Murundus seriam relevos residuais resultantes da ação erosiva diferencial provocada por escoamento superficial. Portanto, para a hipótese geomorfológica, a formação dos Murundus se daria devido a erosão diferencial provocada pelo escoamento superficial de água, contrariando a hipótese biológica.

Já para outros pesquisadores, a origem dos Murundus seria uma combinação dos fatores geomorfológicos e biológicos. Neto (1981) acredita que a origem dos Murundus se dá a partir de núcleos de grande resistência a erosão por água corrente no solo. Tais núcleos poderiam ser tanto de origem orgânica (cupins), quanto geomorfológica (afloramentos lateríticos). Posteriormente, gramíneas colonizariam tais núcleos, e por meio de seus enraizamentos, o solo seria retido nesses núcleos. Essas seriam então, as condições iniciais para a formação dos Murundus (NETO, 1981). Oliveira-Filho e Furley também acreditam que a origem dos Murundus não está relacionada com apenas um fator, mas sim com a combinação de fatores bióticos e abióticos (OLIVEIRA-FILHO; FURLEY, 1990).

2.1.2.3 Porquê os Murundus são APP?

Em 2007 a Assembleia Legislativa do Estado de Goiás, por meio da lei N° 16.153, de 26 de Outubro de 2007, decretou os Campos de Murundus como Áreas de Preservação Permanente (APP's) para o estado do Goiás. A definição de Campos de Murundus se dá no primeiro artigo dessa lei como pode ser visto a seguir.

Art. 1º Ficam consideradas como Áreas de Preservação Permanente para fins de licenciamento ambiental, os campos de Murundus, conhecidos regionalmente no sudoeste goiano como covais.

§ 1º Entende-se por campos de murundus uma fitofisionomia do Bioma Cerrado que consiste basicamente em um campo úmido, em terreno pouco inclinado, com ilhas de campo limpo ou cerrado, arredondadas, com cerca de 1 a 10 metros de diâmetros, por decímetros de altura, localizados geralmente a montante de nascentes e ou olhos d'água e ao longo dos mananciais.

§ 2º Os campos de murundus caracterizam-se pela ocorrência de solos hidromórficos, de coloração acinzentada permanentemente saturados por água, associados a presença de aquíferos suspensos aflorantes e subaflorantes considerados também, como zona de recarga do aquífero livre ou lençol freático.

§ 3º Os campos de murundus constituem área de reserva de biodiversidade, tanto da flora como da fauna.

Já o artigo segundo dessa lei trata da identificação e delimitação dos Murundus, enquanto os artigos terceiro e quarto tratam da utilização das áreas próximas aos Murundus.

Art. 2º Para fim de identificação e delimitação da extensão dos campos de murundus deve ser observada, quando da avaliação de processos para licenciamento, a presença de solos hidromórficos e a ocorrência de vegetação característica de solos de campos úmidos, para em seguida solicitar vistorias em campo que permita conferir as demais características apresentadas nos parágrafo 1º, 2º e 3º do art. 1º.

Art. 3º A supressão da vegetação e a utilização de áreas localizadas próximas a campos de murundus para drenagem, cultivo, pastoreio e outras atividades, devem atender as seguintes exigências:

I – manter um raio mínimo de 50 metros de largura ao redor das áreas de campos de murundus, podendo ser esta distância ampliada, de acordo com as peculiaridades locais, a partir de parecer técnico emitido após vistoria em campo;

II – exigência de prévia avaliação de impacto ambiental, sem prejuízo de outros estudos técnicos que fizerem necessários;

III – aprovação prévia do corpo técnico dos órgãos estaduais competentes, conforme regulamento, como condição essencial à legalização da instalação e do funcionamento de atividades em área próxima a campos de murundus.

Art. 4º Para atividades implantadas antes da vigência desta Lei e exploradas por mais de 2 (dois) anos, o licenciamento ou sua renovação fica condicionada à prévia aprovação do corpo técnico, previsto no artigo anterior, que fixará os estudos técnicos adequados além de outras exigências que se fizerem necessárias.

Além da lei Nº 16.153, de 26 de Outubro de 2007, o Instituto do Meio Ambiente e dos Recursos Hídricos do Distrito Federal editou uma normativa, instrução Nº 39 de 21 de Fevereiro de 2014, que classifica os Campos de Murundus também como Áreas de Preservação Permanente (APP), porém agora para territórios do DF. De acordo com tal normativa, os Murundus são classificados como elevações arredondas ou ovais com dimensões variadas, desde poucos centímetros a 2 metros e cujo diâmetro pode alcançar até 10 metros. Os artigos 3º e 4º são provavelmente os mais importantes dessa normativa. Neles estão detalhadas as instruções de como áreas localizadas próximas a Campos de Murundus devem ser manejadas. Segue abaixo a explicação de tais artigos.

Art. 3º A supressão da vegetação e a utilização de áreas localizadas próximas a campos de murundus para drenagem, cultivo, pastoreio e outras atividades, devem atender as seguintes exigências:

I – manter um raio mínimo de proteção de 50 (cinquenta) metros de largura, em projeção horizontal, ao redor das áreas de campos de murundus, podendo esta distância ser ampliada, de acordo com as peculiaridades locais, a partir de parecer técnico emitido após vistoria em campo por técnicos do IBRAM;

II – obter autorização prévia do setor competente pela análise de pedidos de supressão no IBRAM;

III – quando se tratar de imóvel rural, apresentação prévia das Informações Ambientais de Imóvel Rural ao IBRAM.

Art. 4º No caso de áreas rurais consolidadas até 22 de julho de 2008 em campos de murundu, será obrigatória a recomposição das faixas marginais, em projeção horizontal, delimitadas ao redor ao redor dos campus de murundu, de largura mínima de:

I – 30 (trinta) metros, para imóveis rurais com área de 4 (quatro) módulos fiscais; e

II – 50 (cinquenta) metros, para imóveis rurais com área superior a 4 (quatro) módulos fiscais. Parágrafo único. Será considerada, para fins do disposto no caput e seus incisos, a área detida pelo imóvel rural em 22 de julho de 2008.

Tanto lei N° 16.153, de 26 de Outubro de 2007, quanto a instrução N° 39 de 21 de Fevereiro de 2014, deixam evidente a importância dos Campos de Murundus para o meio ambiente. Portanto, é de grande importância o monitoramento dessas áreas para que a lei seja seguida e para que não haja degradação do meio ambiente.

2.2 Sensoriamento Remoto

O Sensoriamento Remoto (SR) se fundamenta basicamente na propriedade dos materiais de absorver, transmitir e de refletir radiação eletromagnética (REM). Para Lintz e Simonett, sensoriamento remoto é a aquisição de dados físicos de um objeto não havendo contato com o mesmo ([LINTZ; SIMONETT, 1976](#)). Já para James Campbell e Randolph Wynne, sensoriamento remoto é a prática de obter informações sobre a superfície terrestre e superfícies de corpos d'água usando imagens adquiridas a partir de uma perspectiva aérea, utilizando radiação em uma ou mais regiões do espectro eletromagnético, ou emitida a partir da superfície da Terra ([CAMPBELL; WYNNE, 2011](#)).

A Fig. 2.2.1 ilustra um exemplo de imagem de sensoriamento remoto obtida por meio do sensor OLI do satélite LandSat 8 no território de Brasília.



Figura 2.2.1 – Imagem de SR, LandSat 8

2.2.1 Imagens Digitais

Uma imagem digital é representada por uma matriz de pixels na qual o valor de cada pixel (do inglês, *picture element*) representa uma quantidade discreta chamada de nível de cinza (NC). Gonzalez e Woods (2010) definem uma imagem como uma função bidimensional, $f(x, y)$, em que x e y são coordenadas espaciais (plano), e a amplitude de f em qualquer par de coordenadas (x, y) é chamada de intensidade ou nível de cinza da imagem nesse ponto.

Para imagens digitais, o nível de cinza mínimo para um pixel equivale a zero, o que corresponde à cor preta. Já o NC máximo (cor branca) seria um número positivo finito igual a $2^n - 1$, em que " n " representa a quantidade de Bits com que a devida imagem foi amostrada. Em outras palavras, " n " representa a resolução radiométrica da imagem. Imagens de 8 Bits ($2^8 = 256$ NCs), como na Fig. 2.2.2, podem ter níveis de cinza entre zero e 255 para cada pixel, na qual a cor branca corresponde a um NC igual a 255 e a cor preta corresponde um NC igual a 0.

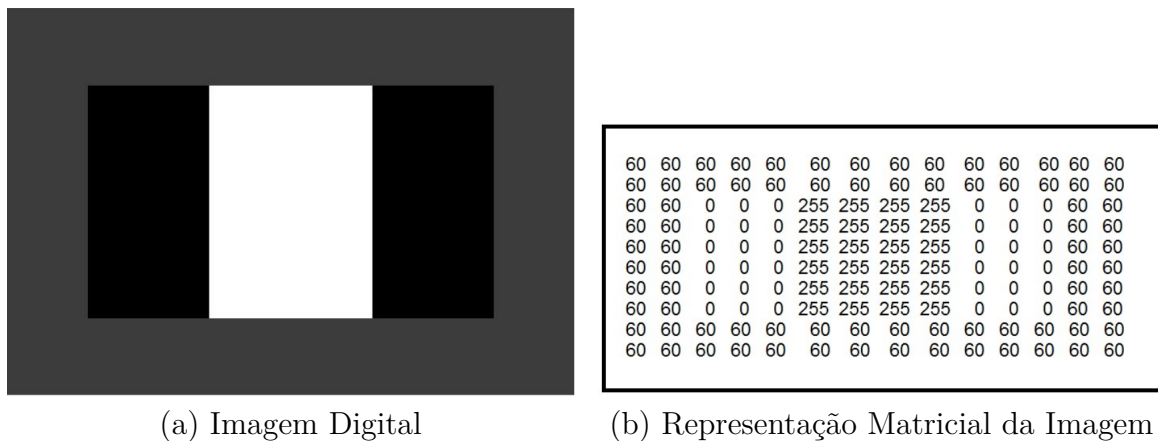


Figura 2.2.2 – Imagem Digital de 8 Bits

2.2.2 Resolução

Quatro divisões podem ser feitas quanto à resolução das imagens de SR, são elas: Resolução Espacial, Espectral, Temporal e Radiométrica.

2.2.2.1 Resolução Espacial

A resolução espacial se refere a menor dimensão que o sensor pode observar. Para James e Randolph, a resolução espacial é definida simplesmente como as dimensões dos menores objetos capturados em uma imagem (CAMPBELL; WYNNE, 2011). Já Crosta (2002) define resolução espacial como a capacidade do sistema sensor em “enxergar” objetos na superfície terrestre; quanto menor o objeto possível de ser visto, maior a resolução espacial. Em outras palavras, a resolução espacial se refere ao tamanho do pixel de uma

imagem de SR. Se, para um determinado sensor, essa resolução for igual a 30 metros, isso significa que cada pixel da imagem possuirá uma área de $30 \times 30 \text{ m}^2$. Portanto, objetos com dimensões menores que 30 m possivelmente não serão observados pelo sensor.

As Figuras 2.2.3 e 2.2.4 ilustram como a resolução espacial pode influenciar na escolha do sistema de SR. Por inspeção visual, percebe-se que a imagem com resolução de 5 metros possui mais detalhes que a imagem com resolução de 20 metros.



Figura 2.2.3 – Imagem do Satélite CBERS 4 de Brasília (Lago Sul), Resolução de 5 m




Figura 2.2.4 – Imagem do Satélite CBERS 4 de Brasília (Lago Sul), Resolução de 20 m

2.2.2.2 Resolução Espectral

A resolução espectral se refere a capacidade que um sensor tem de distinguir objetos em bandas espectrais distintas. Não é apenas a quantidade de bandas espectrais que interfere na resolução espectral de um sensor, mas também a largura de cada banda espectral. Seguindo essa linha de raciocínio, Crósta define a resolução espectral pelo número de bandas espectrais de um sistema sensor e pela largura do intervalo de comprimento de onda coberto por cada banda (CROSTA, 2002). Portanto, para um determinado sensor, quanto mais bandas e menor a largura de cada uma, maior será sua resolução espectral.

2.2.2.3 Resolução Radiométrica

A resolução radiométrica está relacionada à quantidade de bits ou quantidade de Níveis de Cinza (NCs) que uma imagem possui. Quanto maior for a quantidade de NCs por pixel de uma imagem, maior será sua resolução radiométrica e consequentemente, maior será sua riqueza em detalhes. No âmbito do Sensoriamento Remoto, 8,11,12 e 16 bits são resoluções usualmente utilizadas.

As Figuras 2.2.5 e 2.2.6 ilustram o quanto a resolução radiométrica pode influenciar na representação de dados em imagens. A imagem de 3 bits, representada na Fig. 2.2.6, é meramente um exemplo didático, já que essa não é usualmente utilizada para Sensoriamento Remoto.



Figura 2.2.5 – Imagem Landsat8, 8 Bits




Figura 2.2.6 – Imagem Landsat8, 3 bits

2.2.2.4 Resolução Temporal

A resolução temporal é um parâmetro crítico na escolha de um sistema de sensoriamento remoto. De acordo com [Meneses et al. \(2012\)](#), resolução temporal refere-se à periodicidade que o sensor revisita uma área e obtém imagens atualizadas ao longo de sua vida útil. Com isso, essa resolução é o parâmetro que indicará se o sistema de SR escolhido é apropriado ou não para determinada aplicação. Um exemplo no qual a resolução temporal é um parâmetro crucial na escolha do sistema de SR é o caso do monitoramento de desmatamento em florestas. Caso seja necessário monitorar desmatamentos na Amazônia, uma resolução temporal de 60 dias é insuficiente, uma vez que só seria possível obter imagens atualizadas a cada 2 meses. Uma resolução mais adequada seria de 15 dias, onde teríamos imagens 2 vezes ao mês, possibilitando uma análise temporal mais apropriada para essa aplicação.

2.2.3 Índices de Vegetação

Com o avanço das tecnologias satelitais foi possível o desenvolvimento de satélites com resoluções melhores, tanto espacial quanto espectral. Assim, com mais bandas espectrais disponíveis, métodos matemáticos foram desenvolvidos para obtenção de dados geográficos e ambientais a partir de operações aritméticas entre bandas espectrais distin-

tas. Tais métodos foram chamados de Índices de Vegetação, e possibilitaram uma melhor interpretação de dados de solo, vegetação e recursos hídricos de uma área imageada.

Para (CAMPBELL; WYNNE, 2011), os índices de vegetação são descritos da seguinte forma:

“Os índices de vegetação (*Vegetation Indices* – VIs), com base nos valores de brilho digital, tentam medir a biomassa ou o vigor vegetativo. Um VI é formado a partir de combinações de vários valores espectrais que são adicionados, divididos ou multiplicados de uma maneira a produzir um único valor que indica a quantidade ou o vigor da vegetação dentro de um pixel. Valores altos do VI identificam pixels cobertos por proporções substanciais de vegetação saudável.”

2.2.3.1 NDVI

Um dos índices de vegetação mais utilizados é o Índice de Vegetação da Diferença Normalizada (*Normalized Difference Vegetation Index*, NDVI). O NDVI, proposto por [Jr et al. \(1974\)](#), pode variar entre 1 e -1 e é calculado a partir da reflectância de duas bandas distintas, são elas: Banda do Vermelho (*Red*) e Banda do Infravermelho Próximo (NIR, do inglês *Near Infrared*), de acordo com 2.1:

$$NDVI = \frac{\rho_{NIR} - \rho_{Red}}{\rho_{NIR} + \rho_{Red}} \quad (2.1)$$

em que ρ_{NIR} representa a reflectância da banda do infravermelho próximo (NIR) e ρ_{Red} representa a reflectância da banda do vermelho. A Fig. 2.2.7 representa o NDVI para a cidade de Brasília.




Figura 2.2.7 – NDVI de Brasília, Satélite LandSat 8 (OLI)

Com o NDVI calculado, é possível extrair bastante informação sobre a área imageada, tais como: medida de índice de área foliar e determinação da porcentagem de cobertura do solo. Tal índice possui valor acima de zero para áreas com cobertura vegetal e valor menor que zero para regiões onde não existe tal cobertura.

2.2.3.2 SAVI

Huete (1988) propôs um novo índice de vegetação chamado de Índice de Vegetação Ajustado ao Solo (*Soil Adjusted Vegetation Index* – SAVI). De acordo com o autor, o NDVI é bastante sensível aos diferentes tipos de solo, portanto, uma constante “L” foi adicionada a fórmula do NDVI. Com isso, um novo índice (SAVI) seria gerado, de acordo com a expressão 2.2:

$$SAVI = \frac{\rho_{NIR} - \rho_{Red}}{\rho_{NIR} + \rho_{Red} + L} \cdot (L + 1), \quad (2.2)$$

em que L representa uma constante que depende do tipo de solo. O fator de multiplicação $(L + 1)$ foi acionado para garantir os mesmos limites (-1 a +1) do índice NDVI (HUETE, 1988).

Para determinar qual valor de L seria ótimo para uma ampla gama de densidades de vegetação, Huete variou a constante L , primeiramente, entre 0 a 1 e, posteriormente, entre 1 a 100 analisando os efeitos e sensibilidade das bandas NIR e Red sobre seu índice. Posteriormente foi visto que $L = 1$ seria adequado para áreas com pouca cobertura vegetal, $L = 0.5$ para áreas com cobertura intermediária e $L = 0.25$ para áreas muito densas (HUETE, 1988).

As Figuras 2.2.8 (a), (b), (c) e (d) ilustram o índice SAVI calculado para $L = 1.00$, $L = 0.50$, $L = 0.25$ e $L = 0.00$ respectivamente. Observando-se a Fig. 2.2.8 (d), para $L = 0.00$ o índice SAVI é idêntico ao NDVI, ilustrado na Fig. 2.2.7.

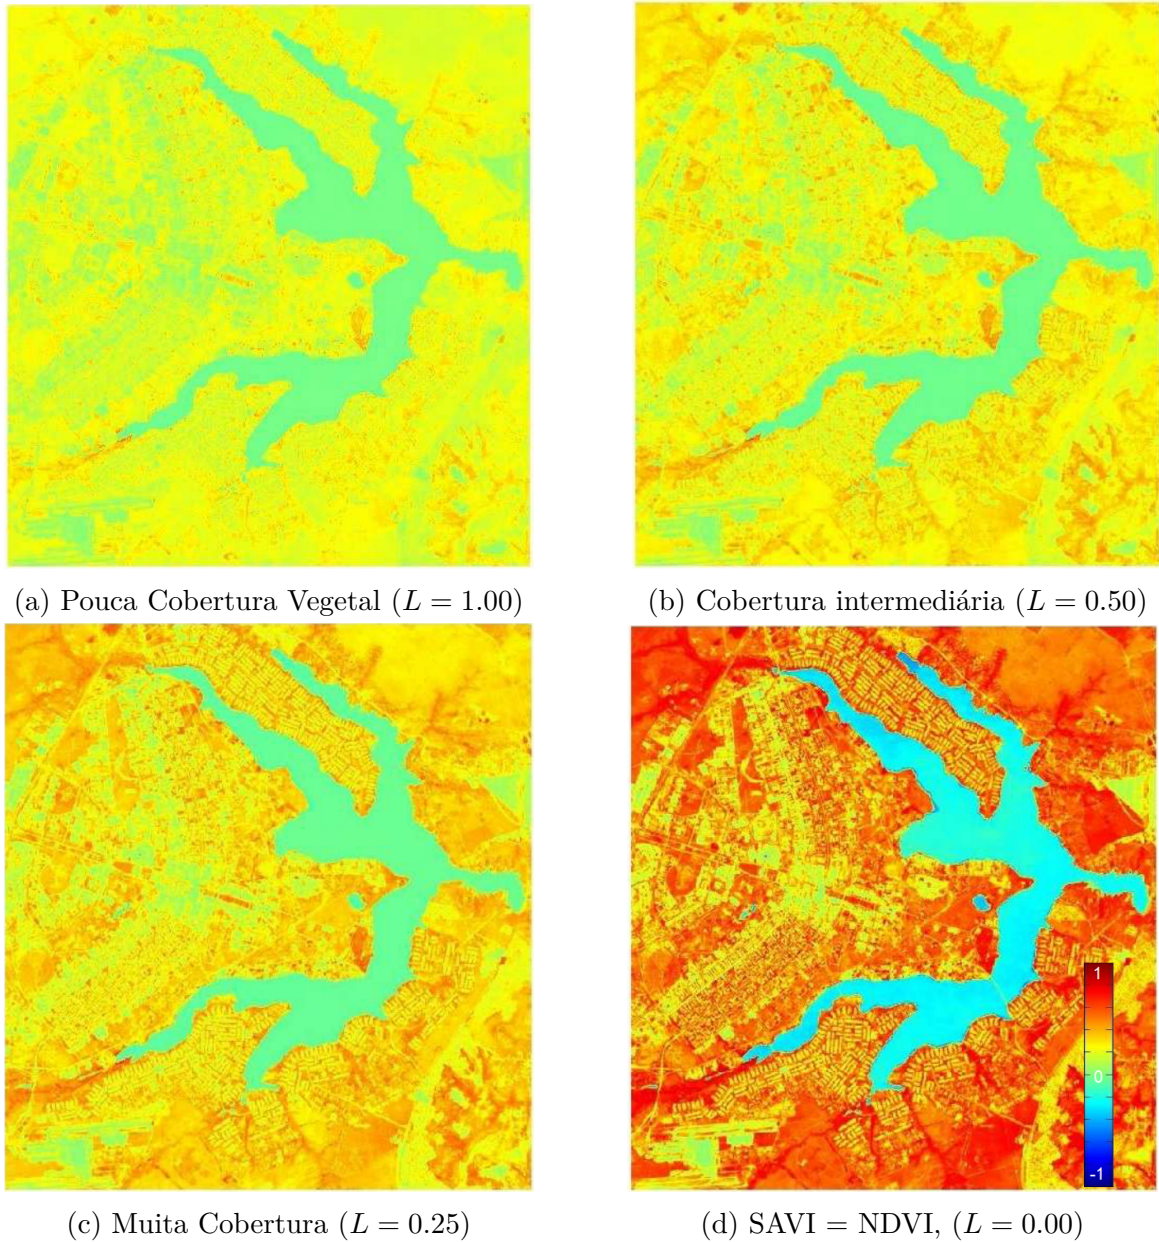


Figura 2.2.8 – SAVI de Brasília, Satélite LandSat 8 (OLI)

2.2.3.3 NDWI

Assim como existem os índices de vegetação para diferentes tipos de solo e vegetação, também existem índices de água. Gao (1996) desenvolveu o Índice de Diferença Normalizada da Água (do inglês, *Normalized Difference Water Index* – NDWI). Assim como os índices anteriores, o NDWI de GAO é formado pela combinação da reflectância de duas bandas distintas, são elas: infravermelho próximo (NIR) e infravermelho médio (MIR), de acordo com a equação 2.3:

$$NDWI_{Gao} = \frac{\rho_{NIR} - \rho_{MIR}}{\rho_{NIR} + \rho_{MIR}} \quad (2.3)$$

Em seu trabalho, o autor utilizou as curvas de reflectância de vegetação saudável e de vegetação seca para a criação do NDWI. Além disso, o autor formulou seu índice utilizando a banda NIR centrada em 860 nm e a banda MIR centrada em 1240 nm.

Outros índices de água foram depois desenvolvidos. O NDWI de McFeeters (1996), foi projetado de tal forma a maximizar a reflectância da água utilizando a banda do verde, minimizar a reflectância da banda NIR por objetos d'água e tirar proveito da alta reflectância da banda NIR pela vegetação e solo. Tal índice, utiliza a combinação da reflectância das bandas espectrais do infravermelho próximo (NIR) e do Verde (Green) e é calculado por:

$$NDWI_{McFeeters} = \frac{\rho_{Green} - \rho_{NIR}}{\rho_{Green} + \rho_{NIR}} \quad (2.4)$$

De acordo com o autor, objetos com NDWI acima de zero já podem ser considerados como corpos d'água, enquanto objetos com NDWI abaixo ou igual a zero não podem ser considerados como corpos d'água (MCFEETERS, 1996). A Fig. 2.2.9 ilustra o índice de McFeeters calculado para a região de Brasília por meio de imagens do satélite LandSat8.




Figura 2.2.9 – NDWI de Brasília, Satélite LandSat 8 (OLI)

Percebe-se que o Lago Paranoá, com coloração predominantemente alaranjada, possui NDWI com valor maior que zero, comprovando a ideia de McFeeters sobre corpos d'água possuírem $NDWI > 0$. Existem outros índices de água, por exemplo, o Índice de Diferença Normalizada da Água Modificado (*Modified Normalized Difference Water Index*

– MNDWI) de Xu (XU, 2006). Porém, para o devido trabalho, apenas o índice de água $NDWI_{McFeeters}$ foi utilizando.

2.2.4 Plataformas

Duas Plataformas satelitais foram escolhidas pra monitoramento dos Murundus, são elas: *Landsat 8* e *Cbers 4*.

2.2.4.1 LandSat

No começo da era satelital, a observação da Terra era feita apenas por satélites meteorológicos ou imagens capturadas por aviões. Com isso, a NASA, com o apoio dos departamentos de administração do governo dos EUA, começou o projeto LandSat, ilustrado na Fig. 2.2.10 (CAMPBELL; WYNNE, 2011). Primeiramente o projeto LandSat (contração da expressão *Land Satellite*) era chamado de ERTS (*Earth Resources Technology Satellite*), com o lançamento do satélite ERTS-1 em 23 de Julho de 1972.




Figura 2.2.10 – Missões Landsat (Fonte: <https://landsat.gsfc.nasa.gov/a-landsat-timeline/>)

ERTS-1 ficou operacional até 6 de Janeiro de 1978 e representou um grande avanço para sistemas de observação da Terra, já que era o primeiro satélite multi-espectral projetado especificamente para adquirir dados sobre recursos terrestres em uma base sistemática, repetitiva e de média resolução (CAMPBELL; WYNNE, 2011). Após o lançamento do ERTS-2, em 22 de Janeiro de 1975, a NASA oficialmente renomeou o projeto ERTS para Landsat, assim, ERTS-1 e ERTS-2 se tornaram Landsat 1 e Landsat 2, respecti-

vamente. Até a presente data (2018), um total de oito missões Landsat foram lançadas (Landsat 1 a 8), e em apenas uma missão ocorreu falha no lançamento (Landsat 6).

Observando-se a Fig. 2.2.10, percebe-se que os satélites Landsat 7 e Landsat 8 são os únicos que continuam em operação hoje, porém não é mais recomendada a utilização das imagens fornecidas pela plataforma Landsat 7 devido a uma falha de hardware ocorrida nessa plataforma em Maio de 2003. A Tabela 2.2.1 ilustra as características dos sensores utilizados nas missões Landsat 1 a 7. No total, cinco diferentes sensores foram utilizados nessas plataformas, são eles: RBV (*Return Beam Vidicon*), MSS (*Multispectral Scanner System*), TM (*Thematic Mapper*), ETM (*Enhanced Thematic Mapper*) e a ETM+ (*Enhanced Thematic Mapper Plus*).

Tabela 2.2.1 – Sensores utilizados nas missões Landsat 1 a 7

Sensor	Missão	Faixa Espectral [nm]	Resolução [m]
RBV	1,2	475 - 575	80
		580 - 680	80
		690 - 830	80
	3	505 - 750	30
MSS	1-5	500 - 600	79/82 ^a
		600 - 700	79/82 ^a
		700 - 800	79/82 ^a
		800 - 1100	79/82 ^a
	3	1040 - 1260	240
TM	4,5	450 - 520	30
		520 - 600	30
		630 - 690	30
		760 - 900	30
		1550 - 1750	30
		2080 - 2350	30
		1040 - 1250	120
ETM	6	Bandas TM acima mais 500 - 900	30 (120 Banda Termal) 15
ETM+	7	Bandas TM acima mais 500 - 900	30 (60 Banda Termal) 15

^a 79 m para Landsat 1 a 3 e 82 m para Landsat 4 e 5

O Landsat 8, lançado em 11 de Janeiro de 2013, está em uma órbita Hélio-Síncrona a 705 km e com 98.2° de inclinação (WRS-2). Tal plataforma possui duas câmeras para imageamento terrestre, são elas: OLI (*Operational Land Imager*) e TIRS (*Thermal Infra-red Sensor*). O sensor OLI possui nove bandas espectrais enquanto o sensor TIRS possui apenas duas, como representado na Tab. 2.2.2.

Tabela 2.2.2 – Sensores Landsat 8

Sensor	Banda	Faixa Espectral [nm]	Resolução [m]
OLI	1 - Aerosol	435 - 451	30
	2 - Azul	452 - 512	30
	3 - Verde	533 - 590	30
	4 - Vermelho	636 - 673	30
	5 - NIR	851 - 879	30
	6 - SWIR 1	1566 - 1651	30
	7 - SWIR 2	2107 - 2294	30
	8 - Pan	503 - 676	15
	9 - Cirrus	1363 - 1384	30
TIRS	10 - TIR 1	10600 - 11190	100
	11 - TIR 2	11500 - 12510	100

Como ilustrado na Fig. 2.2.11, o sensor OLI possui duas novas bandas espectrais que não existiam no antigo ETM+ (Banda 1 e 9). Uma dessas novas faixas espectrais serve para detecção de nuvens enquanto a outra serve pra observação de zonas costeiras.




Figura 2.2.11 – Sensores Landsat 7 e 8 (Fonte: <https://landsat.gsfc.nasa.gov/landsat-data-continuity-mission/>)

2.2.4.2 CBERS

O Satélite Sino-Brasileiro de Recursos Terrestres (CBERS, do inglês *China-Brazil Earth Resources Satellite*) é uma parceria entre os governos brasileiro e chinês, assinada por meio de acordo em 06 de Julho de 1988. O primeiro satélite CBERS (CBERS 1), ilustrado na Fig. 2.2.12, foi lançado com sucesso em 14 de Outubro de 1999 pelo foguete chinês Longa Marcha 4B, do Centro de Lançamento de Taiyuan, enquanto o CBERS 2 foi lançado em 21 de Outubro de 2003.



Características	
Massa total	1450kg
Potência gerada	1100 W
Baterias	2 x 30 Ah NiCd
Dimensões do corpo	(1,8 x 2,0 x 2,2) m
Dimensões do painel	6,3 x 2,6 m
Altitude da órbita hélio-síncrona	778 km
Propulsão a hidrazina	16 x 1 N; 2 x 20 N
Estabilização	3 eixos
Supervisão de bordo	Distribuída
Comunicação de Serviço (TT&C)	UHF e banda S
Tempo de vida (confiabilidade de 0,6)	2 anos

Figura 2.2.12 – CBERS 1 e 2, Características (Fonte: www.cbers.inpe.br (Adaptado))

Como os CBERS 1 e 2 são idênticos, eles possuem as mesmas cargas úteis. Dentre a carga útil, os componentes que têm mais valor para as aplicações de sensoriamento remoto são as câmeras. Ambos os satélites possuem três câmeras para imageamento terrestre, quais sejam, HR CCD (do inglês, *High Resolution Charge Coupled Device*), IRMSS (do inglês, *Infrared Multi Spectral Scanner*) e WFI (do inglês, *Wide Field Imager*), representadas pelas Tabelas 2.2.3, 2.2.4 e 2.2.5, respectivamente.

Tabela 2.2.3 – WFI (Fonte: www.cbers.inpe.br)

Bandas Espectrais	630 - 690 nm (Vermelho) 770 - 890 nm (IR)
Campo de Visada	60°
Resolução Espacial	260 m
Largura da Faixa Imageada	890 km
Resolução Temporal	5 dias
Frequência da portadora de RF	8203,35 MHz
Taxa de dados da imagem	1.1 Mbit/s
Potência efetiva isotrópica irradiante	31.8 dBm

O sensor WFI, representado pela Tab. 2.2.3, possui apenas 2 bandas espectrais (faixa do vermelho e infravermelho), com uma resolução espacial de 260 metros para

ambas bandas. Por ter uma alta largura de faixa, e por sua pobre resolução espacial, tal sensor consegue cobrir toda a superfície terrestre em apenas 5 dias. Em outras palavras, o WFI possui uma ótima resolução temporal em detrimento de sua baixa resolução espacial.

Tabela 2.2.4 – HR CCD (Fonte: www.cbers.inpe.br)

Bandas Espectrais [nm]	510 - 730 (Pan) 450 - 520 (Azul) 520 - 590 (Verde) 630 - 690 (Vermelho) 770 - 890 (NIR)
Campo de Visada	8.3°
Resolução Espacial	20 m
Largura da Faixa Imageada	113 km
Capacidade a apontamento do espelho	$\pm 32^\circ$
Resolução Temporal	26 dias (com visada vertical) 03 dias (com visada lateral)
Frequência da portadora de RF	8103 e 8321 MHz
Taxa de dados da imagem	2 x 53 Mbit/s
Potência efetiva isotrópica irradiante	43 dBm

A câmera CCD, representado pela Tab. 2.2.4, possui 5 bandas espectrais, todas com 20 metros de resolução. De acordo com o INPE (Instituto Nacional de Pesquisas Espaciais), “esta câmera tem capacidade de orientar seu campo de visada dentro de ± 32 graus, possibilitando a obtenção de imagens estereoscópicas de certa região. Além disso, qualquer fenômeno detectado pela WFI pode ser focalizado pela câmera CCD, para estudos mais detalhados, através de seu campo de visada, no máximo a cada três dias” (www.cbers.inpe.br).

Tabela 2.2.5 – IRMSS (Fonte: www.cbers.inpe.br)

Bandas Espectrais [nm]	500 - 1100 (Pan) 1550 - 1750 (SWIR 1) 2080 - 2350 (SWIR 2) 10400 - 12500 (TIR)
Campo de Visada	8.8°
Resolução Espacial	80 m
Largura da Faixa Imageada	120 km
Capacidade a apontamento do espelho	$\pm 32^\circ$
Resolução Temporal	26 dias
Frequência da portadora de RF	8216.84 MHz
Taxa de dados da imagem	6.13 Mbit/s
Potência efetiva isotrópica irradiante	39.2 dBm

Já o sensor IRMSS, ilustrado pela Tab. 2.2.5, possui apenas 4 bandas espectrais, da banda pancromática até a banda do infravermelho termal. Observando-se a Tab. 2.2.5,

tal câmera possui 80 metros de resolução espacial para as três primeiras bandas e 160 metros para a faixa termal.

O satélite CBERS 2B, ilustrado na Fig. 2.2.13, foi lançado da base de Taiyuan no dia 19 de Setembro de 2007 e também pertencente a primeira geração do programa CBERS.



Figura 2.2.13 – CBERS 2B (Fonte: www.cbers.inpe.br (Adaptado))

Poucas foram as mudanças entre o CBERS 2B e o CBERS 2. De acordo com o INPE, a principal melhoria foi “a substituição do imageador IRMSS por uma Câmera Pancromática de Alta Resolução (do inglês, *High Resolution Camera* - HRC), ilustrado na Tab. 2.2.6. Outras melhorias são um novo sistema de gravação a bordo e um sistema avançado de posicionamento, que inclui GPS (do inglês, *Global Positioning System*) e sensor de estrelas”.

Tabela 2.2.6 – HRC (Fonte: www.cbers.inpe.br)


Bandas Espectrais	500 - 800 nm (Pan)
Campo de Visada	2.1°
Resolução Espacial	2.7 m
Largura da Faixa Imageada	27 km (nadir)
Resolução Temporal	130 dias
Taxa de dados da imagem	432 <i>Mbit/s</i>
Quantização	8 bits

A câmera HRC possui apenas uma banda espectral (Pancromática), com 2.7 metros de resolução. Por ter uma ótima resolução espacial e uma estreita largura de imageamento, tal sensor requer um período de 130 dias para imagear toda superfície terrestre.

Em novembro de 2002 os governos brasileiro e chinês decidiram dar continuidade ao Programa CBERS, iniciando, portanto, a segunda geração de satélites CBERS. Dessa nova fase, estão listados os satélites CBERS 3 e 4. Ao contrário da primeira geração, durante a qual o Brasil contribui 30% do projeto e a China com 70%, agora ambos os países participaram com 50% das etapas da nova geração CBERS.

O CBERS-3 foi lançado em 9 de dezembro de 2013, porém, “devido a uma falha de funcionamento do veículo lançador Longa Marcha 4B, o CBERS-3 não foi posicionado na órbita prevista resultando em sua reentrada na atmosfera da Terra” (www.cbers.inpe.br). Já o CBERS-4 foi lançado no dia 07 de dezembro de 2014. Assim como os satélites anteriores de sua família, CBERS-4 também foi lançado da base de Tayuan na China. Ao contrário de seu antecessor, o lançamento do CBERS-4 foi um sucesso e ele continua operando até a presente data em uma órbita Hélio-Síncrona à 778 km de altitude e com 98.504° de inclinação.

A Fig. 2.2.14 ilustra algumas diferenças entre a duas gerações do programa CBERS. Além dessas, segundo o INPE, “para os CBERS-3 e 4, são utilizadas no módulo carga útil quatro câmeras (Câmera Pancromática e Multiespectral - PAN, Câmera Multiespectral Regular - MUX, Imageador Multiespectral e Termal - IRS, e Câmera de Campo Largo - WFI) com desempenhos geométricos e radiométricos melhorados.”



Característica	CBERS 1, 2 e 2B	CBERS 3 e 4
Massa total	1450 kg	2080 kg
Potência gerada	1100 W	2300 W
Taxa de dados	100 Mbit/s	300 Mbit/s
Vida útil projetado	2 anos	3 anos
Participação brasileira	30 %	50 %

Figura 2.2.14 – CBERS 3 e 4 (Fonte: www.cbers.inpe.br (Adaptado))

A câmera PAN possui 4 bandas espectrais (pancromática, verde, vermelho e infravermelho próximo), com 5 metros de resolução para a faixa pancromática e 10 metros para as demais. Além disso, ela é a única câmera da segunda geração CBERS que possui espelho de visada lateral, possibilitando um melhor tempo de revisita para esse sensor.

O sensor de imageamento MUX é o sucessor da antiga CCD. Essa nova câmera possui 4 bandas espectrais (Azul, Verde, Vermelho e NIR) com 20 metros de resolução para todas as faixas espectrais. Uma novidade é que essa nova câmera é produzida inteiramente

no Brasil, ao contrário da CCD. Todos os quatro sensores mencionados para a nova geração CBERS estão ilustrados pelas Tabelas 2.2.7 e 2.2.8.

A câmera IRS veio para substituir a IRMSS da primeira geração. Como pode ser observado na Tab. 2.2.8, esse novo sensor possui 40 metros de resolução nas bandas pancromática e SWIR (Infravermelho de Ondas Curtas, do inglês, *Short-Wave Infrared*) e 80 metros na banda Termal (do inglês, *Thermal Infrared* - TIR).

Tabela 2.2.7 – Câmeras CBERS 3 e 4 (Fonte: www.cbbers.inpe.br)

	MUX	PAN
Bandas Espectrais nm	450 - 520 (B) 520 - 590 (G) 630 - 690 (R) 770 - 890 (NIR)	0.51 - 0.85 (Pan) 0.52 - 0.59 (G) 0.63 - 0.69 (R) 0.77 - 0.89 (NIR)
Resolução	20 m	5 m / 10 m
Largura da Faixa Imageada	120 km	60 km
Apontamento	Não	$\pm 32^\circ$
Revisita	26 dias	5 dias
Revisita Real	26 dias	Não
Quantização	8 bits	8 bits
Taxa de dados Bruta Mbits/s	68	140 100

Tabela 2.2.8 – Câmeras CBERS 3 e 4 (Fonte: www.cbbers.inpe.br)

	IRS	WFI
Bandas Espectrais nm	500 - 900 (Pan) 1550 - 1750 (SWIR) 2080 - 2350 (SWIR) 10400 - 12500 (TIR)	0.45 - 0.52 (B) 0.52 - 0.59 (G) 0.63 - 0.69 (R) 0.77 - 0.89 (NIR)
Resolução	40 m / 80 m	64 m
Largura da Faixa Imageada	120 km	866 km
Apontamento	Não	Não
Revisita		
Revisita Real	26 dias	5 dias
Quantização	8 bits	10 bits
Taxa de dados Bruta Mbits/s	16	50

O novo WFI da segunda geração possui mais bandas espectrais e uma melhor resolução espacial. Além disso, ele também é agora produzido nacionalmente e possui 64 metros de resolução em comparação a 260 metros do antigo sensor, como pode ser notado na Tab. 2.2.8.

3 Metodologia

Com o auxílio da interface gráfica do *Matlab* (GUIDE), foi desenvolvido um software para monitoramento ambiental, ilustrado na Fig. 3.0.1. Tal software foi chamado de EcoTool, e suporta tanto dados Landsar 8 (OLI) quanto CBERS 4 (MUX e PAN10m).

A plataforma desenvolvida possibilita inúmeras aplicações para sensoriamento remoto, tais como: Georreferenciamento de Imagens, Registro de Imagens, Geração de Índices de Vegetação e Construção Automática de Máscaras de Nuvens e Sombras de Nuvens.

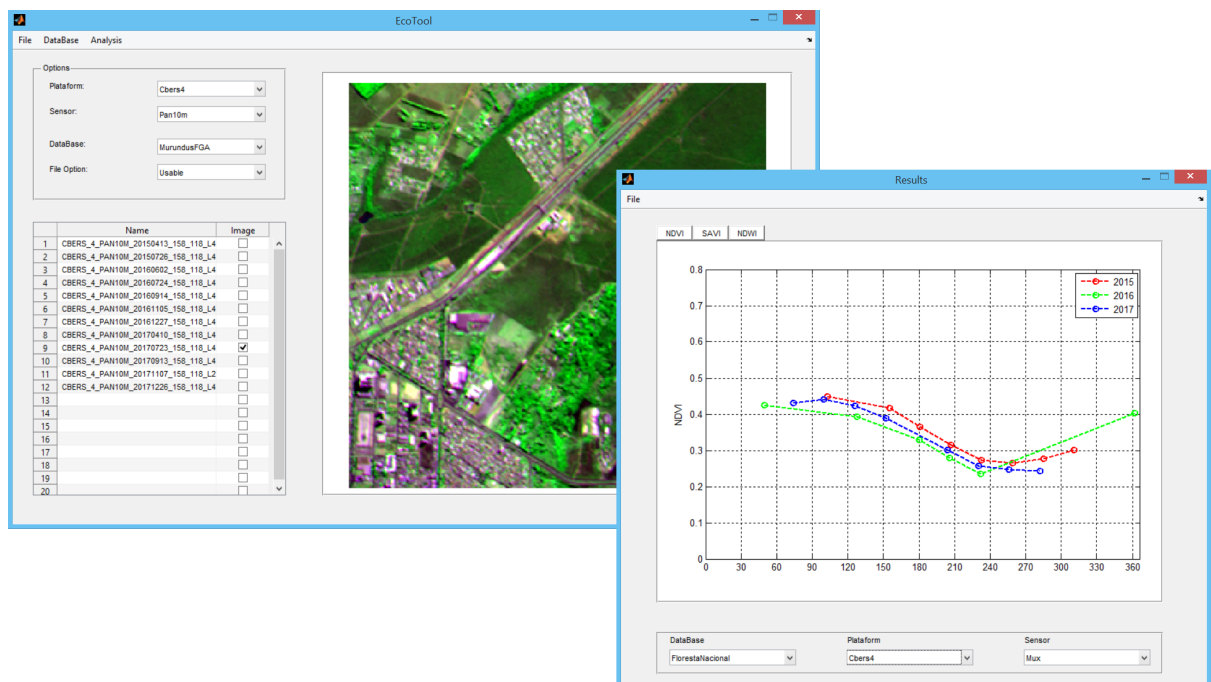


Figura 3.0.1 – EcoTool

O software EcoTool ainda está em fase de testes, porém, pretende-se disponibilizá-lo para a comunidade acadêmica até final de Julho de 2018. Para mais detalhes sobre essa ferramenta, foi desenvolvido um minitutorial de como utilizar EcoTool, disponível nos apêndices deste trabalho.

Todo o processo de monitoramento por sensoriamento remoto segue cinco etapas principais, desde a aquisição de imagens até a análise dos dados. A Fig. 3.0.2 ilustra as cinco etapas para monitoramento via sensoriamento remoto. Na primeira etapa o satélite adquire as imagens das regiões de interesse e as envia para uma estação terrestre.

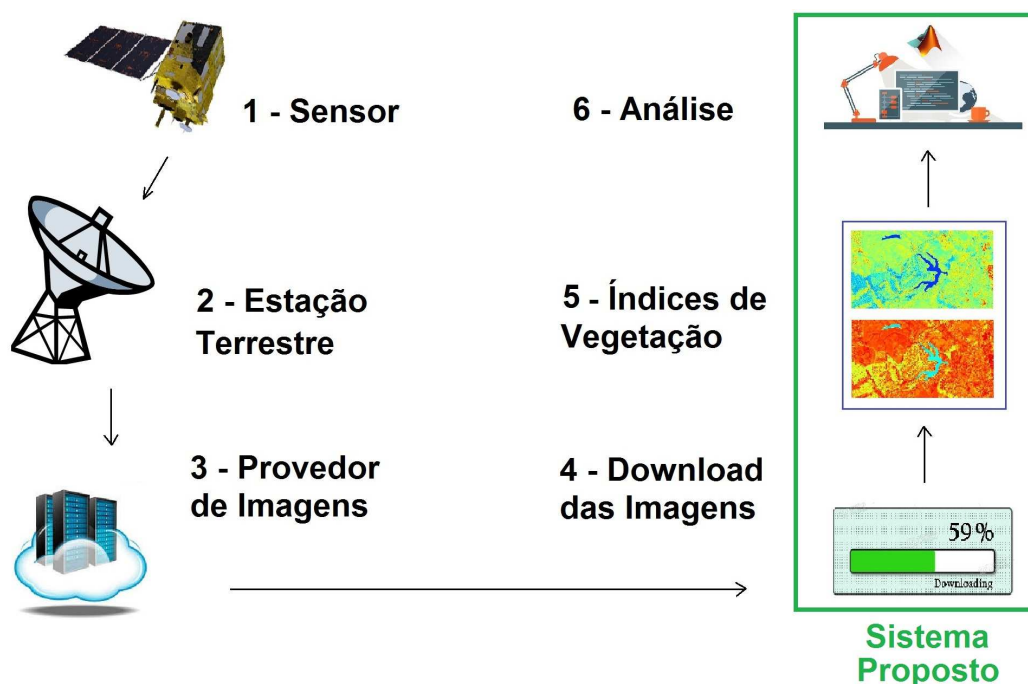


Figura 3.0.2 – Processo Completo de Monitoramento por Sensoriamento Remoto

Na segunda etapa, a estação terrestre faz o pré-processamento das imagens e as torna de domínio público por meio de algum provedor de imagens. No caso do devido trabalho, o provedor de imagens utilizado foi o site do INPE (<http://www.dgi.inpe.br/catalogo/>). Por meio desse site, representado na terceira etapa, também é possível fazer o download de imagens de outras plataformas, tais como: Aqua, Terra, ResourceSat 2 e UK-DMC 2.

Até esse ponto todas etapas apresentadas não fazem parte do escopo do devido trabalho. Na quarta etapa, que já faz parte do escopo do presente trabalho, é feito o download das imagens diretamente do site do provedor. Com isso, as imagens são armazenadas para serem processadas nas próximas etapas.

Na quinta etapa, os índices NDVI, SAVI e NDWI são calculados para as áreas de interesse e armazenados para análise posterior. Com os índices gerados, basta apenas fazer a análise deles para a conclusão do processo de monitoramento. A análise dos dados é feita na última etapa do processo, etapa essa que fica encarregada de analisar os índices durante o decorrer dos meses e estações do ano.

Entre o download das imagens e a fase de análise de dados, sete processos foram seguidos de maneira sistemática, são eles: 1) Correção Geométrica das Imagens, 2) Seleção de Imagem de Referência (Ortofoto), 3) Seleção de Áreas de Estudo, 4) Registro de Imagens, 5) Calibração Radiométrica, 6) Construção de Máscaras e 7) Geração de Índices. A Fig. 3.0.3 ilustra, em forma de diagrama, o sistema proposto para monitoramento dos Murundus via sensoriamento remoto.

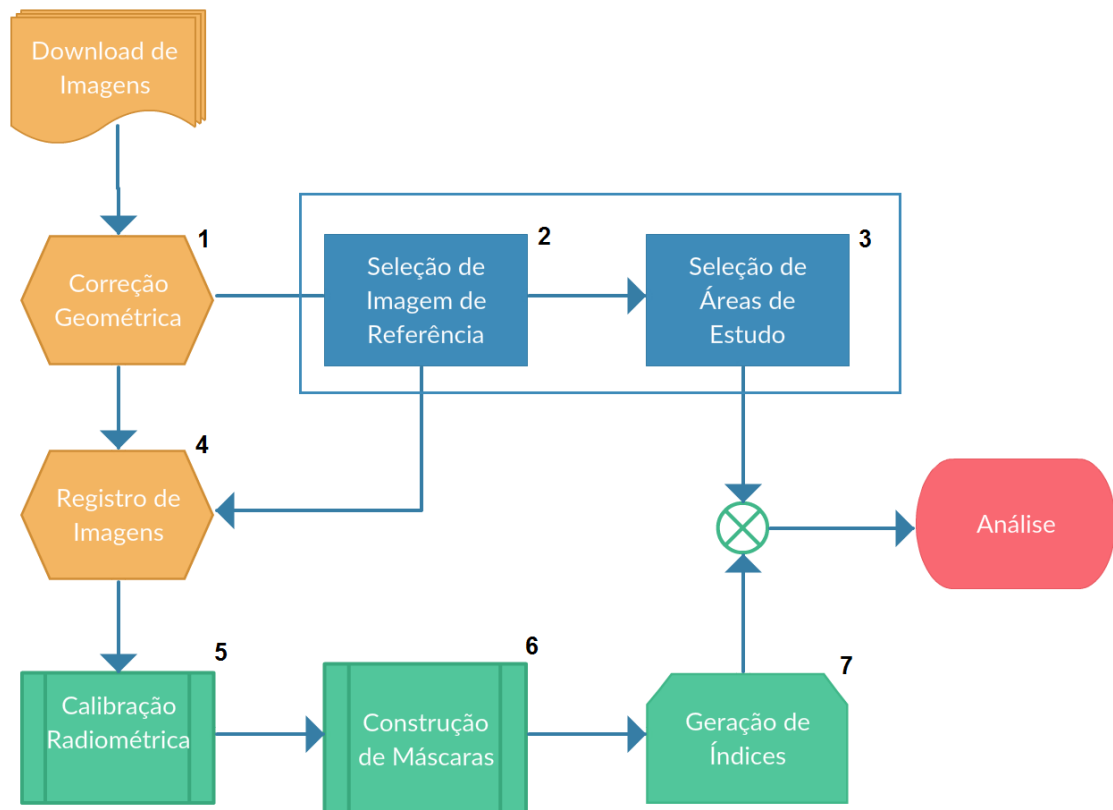


Figura 3.0.3 – Sistema de Monitoramento Proposto

É importante frisar que os processos de seleção de imagem de referência e seleção de áreas de estudo são feitos apenas uma vez (processos 2 e 3). Ao fazer download de novas imagens, esses processos não precisam ser repetidos.

3.1 Download de Imagens

Primeiramente foi criado uma conta e-mail com login “tccmurundus@gmail.com” para fazer os downloads das imagens. Com o e-mail criado, foi necessário criar uma conta no site do INPE (<http://www.dgi.inpe.br/>), provedor de imagens das Plataformas Landsat 8 e CBERS 4.

Ao fazer o login no site do INPE, e entrando na área de catálogo, obtêm-se a interface que possibilita carregar as imagens desejadas. Nessa interface, ilustrada na Fig. 3.1.1, podem ser utilizados cinco parâmetros diferentes para obtenção de imagens, são eles: Parâmetros Básicos, Órbitas e Pontos, Municípios, Região e Interface Gráfica. No devido trabalho apenas as opções Parâmetros Básicos e Municípios foram utilizadas.

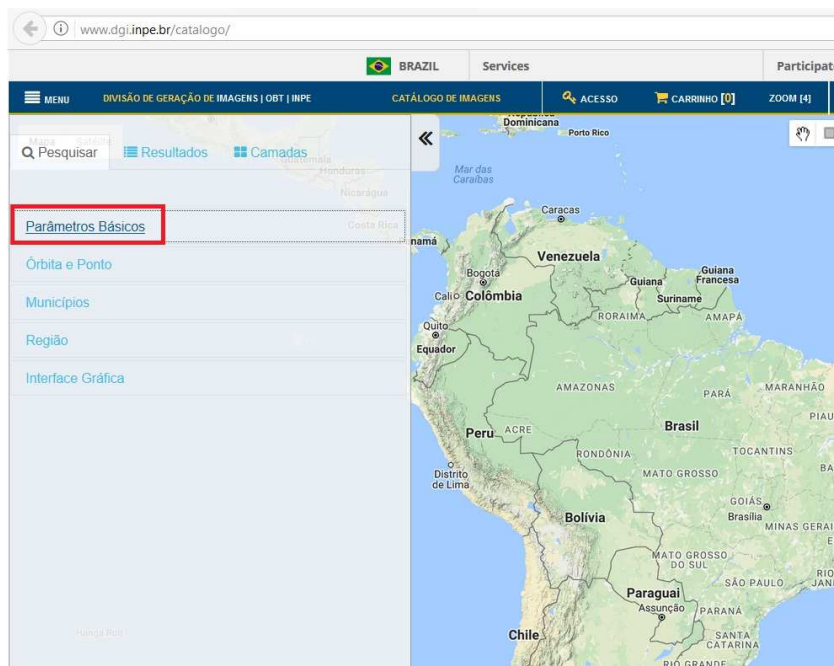


Figura 3.1.1 – Site INPE

A opção **Parâmetros Básicos**, representada na Fig. 3.1.2, fica encarregada da escolha das plataformas e sensores utilizados. Por meio desse parâmetro foram escolhidas as plataformas Landsat 8 e CBERS 4 para o período entre 01/01/2015 a 31/12/2017. Tanto para a plataforma Landsat 8 quanto para CBERS 4 apenas um sensor foi utilizado, sendo o sensor OLI utilizado para o primeiro satélite e o sensor MUX para o segundo. No caso CBERS 4, o sensor PAN 10m não foi utilizado devido ao número limitado de imagens disponíveis para o período desejado.

Figura 3.1.2 – Parâmetros Básicos, INPE

Na opção **Municípios**, ilustrada na Fig. 3.1.3, é possível escolher as áreas de interesse. Portanto, como o objetivo desse trabalho é o monitoramento dos Campos Murundus

do Distrito Federal, a cidade de Brasília foi escolhida como a área de interesse. Assim, após escolher a plataforma, o sensor, o período e a área de interesse, as imagens que se referem a todos os parâmetros selecionados iram ser buscadas pelo servidor.

Parâmetros Básicos

Órbita e Ponto

Municípios

País: BRASIL Estado: DISTRITO FEDERAL

Município (Mínimo de 3 letras)

#	Município	Estado	País
1	Brasilia	DF	Brasil

Região

Interface Gráfica

Figura 3.1.3 – Municípios, INPE

Por fim, foi necessário selecionar as imagens desejadas, solicitá-las por meio do botão **Adicionar ao Carrinho** e finalizar o pedido. Para as imagens CBERS 4, apenas a região 158/118 foi utilizada, como pode ser visto na Fig. 3.1.4. As outras regiões de Brasília não são objetos de análise no devido trabalho.



Figura 3.1.4 – Imagens Selecionadas pelo Servidor, INPE

Ao final do processo de solicitação de imagens, o INPE enviará um e-mail para o cliente com o link por meio do qual pode ser feito o download das imagens. Caso o

download não seja feito em 5 dias, o link torna-se vazio e o cliente deverá fazer uma nova solicitação.

Para fazer o download diretamente do link enviado pelo provedor, foi criado uma rotina em *Matlab* chamada de *GET_DATA_FROM_LINK.m*. Tal rotina faz o download de todos arquivos com extensão “.txt”, “.tif.zip” e “.zip” do link escolhido. A primeira extensão de arquivo se refere ao metadado das imagens Landsat 8, a segunda extensão às imagens Landsat 8 e a última às imagens CBERS 4.

GET_DATA_FROM_LINK.m funciona por meio do programa livre *wget*, originalmente do ambiente Unix. Para isso, tal programa foi instalado em ambiente *Windows* para integração dele com a rotina em *Matlab*. A rotina em *Matlab* se comunica com o prompt de comando *Windows* por meio da função *DOS* possibilitando, portanto, o download dos arquivos com as extensões especificadas. O código fonte da rotina *GET_DATA_FROM_LINK* está disponível no apêndice A do presente trabalho.

3.2 Correção Geométrica

As correções geométricas das imagens foram feitas de duas formas, são elas: Georreferenciação de Imagens e Registo de Imagens. Nessa etapa do projeto as imagens foram apenas georreferenciadas. O processo de registo de imagem foi feito posteriormente e está explicado nos próximos itens desta monografia.

Para [Meneses et al. \(2012\)](#), georreferenciar uma imagem é tornar suas coordenadas conhecidas num dado sistema de referência, processo que se inicia com a obtenção de coordenadas em um sistema de projeção (coordenadas de mapa E-W ou latitude e longitude) e as equivalentes coordenadas espaciais de pontos da imagem a ser corrigida. O georreferenciamento tem desta forma a finalidade de inserir nas imagens um sistema de projeção de coordenadas.

Tanto as imagens Landsat 8 quanto as imagens CBERS 4 são salvas com o formato **geotiff**, que possibilita a extração de dados extras sobre as imagens, como latitude e longitude dos quatro cantos das imagens.

Utilizando-se das informações geográficas presente no formato *geotiff*, e com o auxílio a função *fitgeotrans* do *Matlab*, foi possível georreferenciar as imagens. Com isso, todas as imagens utilizadas foram colocadas no sistema de coordenadas Longitude - Latitude (x - y). A Fig. 3.2.1 ilustra uma imagem CBERS 4 antes e depois da georreferenciação.

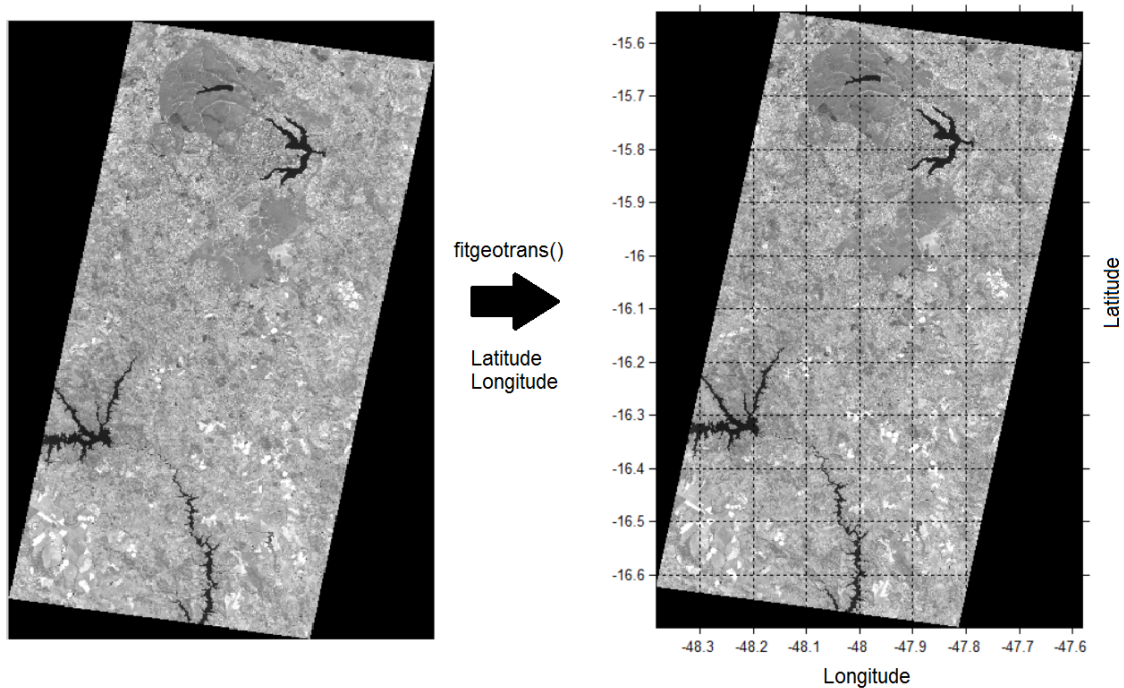


Figura 3.2.1 – Georreferenciamento

A função *fitgeotrans* possui três parâmetros de entradas, e retorna a transformação geométrica necessária para atingir o georreferenciamento escolhido. Os parâmetros de entradas são os seguintes: O tipo de transformada utilizado e as coordenadas de cada um dos quatro cantos da imagem, tanto no sistema de referência da imagem (linha e coluna), quanto no sistema de referência geográfico (latitude e longitude). Para esse trabalho foi escolhido a transformada do tipo *Affine*.

A transformação *Affine* é um método de mapeamento linear que preserva pontos, linhas retas e planos. Tal método é utilizado normalmente para corrigir distorções geométricas ou deformações, fazendo com que conjuntos de linhas paralelas permaneçam paralelas após a transformação. Com isso, quatro tipos de operações se enquadram como transformação *Affine*, são elas: Escala, Translação, Cisalhamento e Rotação. Assim, a transformação *Affine* pode utilizar tanto apenas uma dessas operações, quanto todas as quatro para o processo de georreferenciamento de imagens.

3.3 Seleção de Imagem de Referência

Após o georreferenciamento das imagens, foram selecionadas imagens de referência para cada sensor (OLI e MUX). Essa etapa foi necessária para que fosse possível realizar o registro das imagens na próxima etapa. As imagens de referência, ou Ortofotos, foram selecionadas de tal forma que não houvesse nenhuma nuvem nas Ortofotos, ou seja, cobertura de nuvens igual a zero por cento.

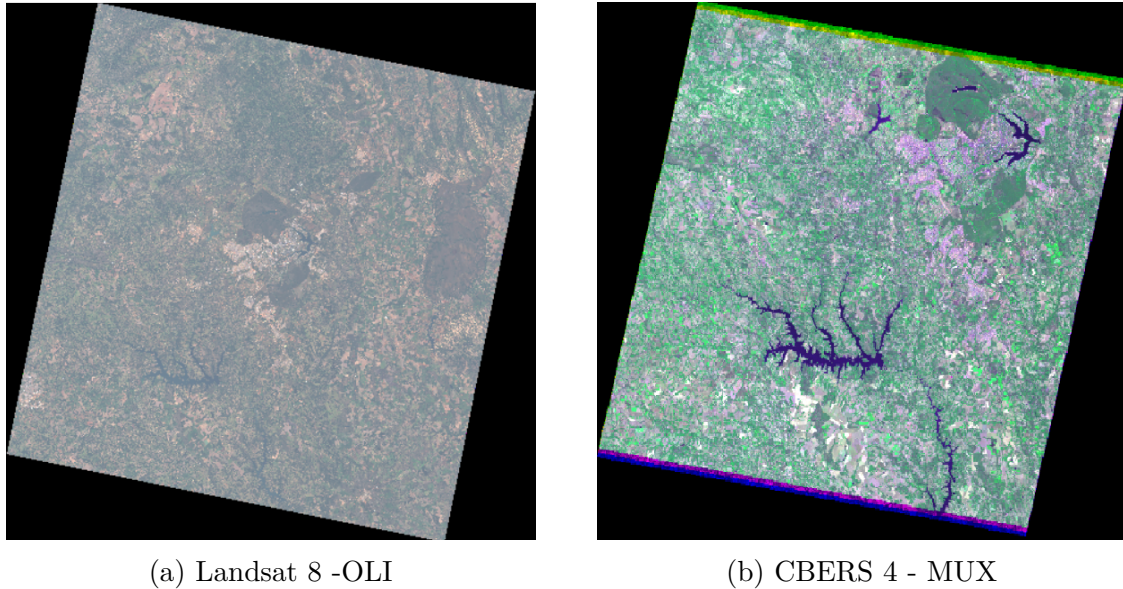


Figura 3.3.1 – Ortofotos

A Fig. 3.3.1 (a), obtida no dia 02 de Maio de 2016, representa a Ortofoto selecionada para o sensor OLI. Já a Fig. 3.3.1 (b), obtida no dia 24 de Julho de 2016, representa a Ortofoto selecionada para o sensor MUX.

3.4 Seleção das Áreas de Estudo

Seis regiões com presença de Campo de Murundus foram selecionadas como áreas de interesse pra esse projeto, são elas: 1) Fazenda Água Limpa – UnB (FAL), 2) Campus Gama da Universidade de Brasília (FGA), 3) Samambaia, 4) Floresta Nacional de Brasília, 5) Parque Nacional de Brasília e 6) Chapada Imperial.

3.4.1 Fazenda Água Limpa – UnB (FAL)

O Campo de Murundus da FAL está representado na Fig. 3.4.1 e fica próximo ao Aeroporto de Brasília (BSB). Tal área foi escolhida para ser monitorado neste trabalho por ser um campo saudável, sem degradação por terceiros, e por já ter sido estudado anteriormente por alguns autores, como Neto (1981).

A Fazenda Água Limpa, pertencente a Universidade de Brasília, possui mais de 4 mil hectares. Os Campos de Murundus estão presentes em diversas áreas da fazenda, porém apenas dois foram selecionados para monitoramento, como ilustrado na Fig. 3.4.1 (b).

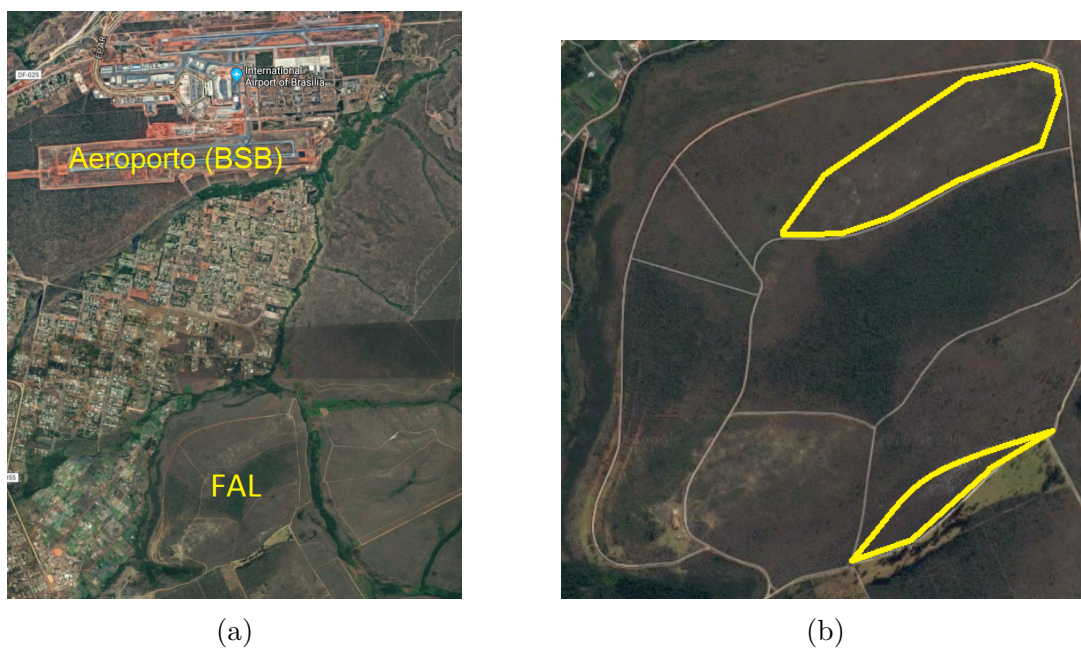


Figura 3.4.1 – (a) Fazenda Água Limpa, (b) Campo de Murundus
(Fonte: Google Earth)

3.4.2 Campus Gama da Universidade de Brasília (FGA)

Ao contrário do Campo de Murundus da FAL, quase não há relatos de pesquisas sobre os Campos de Murundus da FGA. Com isso, para ampliar as pesquisas envolvendo os Murundus dessa área, tal localização também foi escolhida para monitoramento nesse trabalho e está ilustrada na Figuras 3.4.2.



Figura 3.4.2 – Campo de Murundus - FGA, (Fonte: Google Earth)

3.4.3 Samambaia

Os Murundus de Samambaia ficam entre o território de Taguatinga e Samambaia. Mais especificamente, tais Murundus ficam próximos à Brasal Refrigerantes, como pode ser observado na Fig. 3.4.3.



Figura 3.4.3 – Campo de Murundus - Samambaia, (Fonte: Google Earth)

3.4.4 Floresta Nacional de Brasília

A Floresta Nacional de Brasília, ilustrada na Fig. 3.4.4, fica localizada acima da área de Taguatinga Norte.




Figura 3.4.4 – Floresta Nacional, (Fonte: Google Earth)

Os Murundus estão presentes em diversas áreas do parque, porém apenas um Campo de Murundus foi selecionado para monitoramento. A Fig. 3.4.7 representa a região dos Murundus analisada para o Parque Nacional.




Figura 3.4.7 – Campo de Murundus- Parque Nacional, (Fonte: Google Earth)

3.4.6 Chapada Imperial

A Chapada Imperial encontra-se no ponto mais alto do Distrito Federal, com 1342 m de altura, e pertence a Área de Preservação Ambiental (APA) da Cafuringa. A região em amarelo da Fig. 3.4.8 representa a área selecionada para monitoramento na Chapada.




Figura 3.4.8 – Chapada Imperial, (Fonte: Google Earth)

3.5 Registro de Imagem

O Registro de Imagens consiste em operações aritméticas com o intuito de posicionar todas as imagens adquiridas em um mesmo sistema de referência, por isso a importância de ter uma imagem de referência.

Para Meneses, Registro de Imagem é o processo que envolve a superposição de uma mesma cena que aparece em duas ou mais imagens (imagens de bandas diferentes ou imagens de datas diferentes), tal que os pontos correspondentes nessas imagens coincidam espacialmente (MENESES et al., 2012).

Com o intuito de criar um algoritmo automático para registro de imagens, duas soluções foram propostas, são elas: Registro Automático por Detector *SURF* e por Detector de Bordas de *Harris-Stephens*.

SURF (do inglês, Speed-Up Robust Features) é um detector de pontos de interesse, de alto desempenho, invariante as operações de escala e rotação (BAY et al., 2008). Para mais detalhes sobre o funcionamento desse algoritmo recomenda-se a leitura do documento “Speeded-Up Robust Features (SURF) - (BAY et al., 2008)”. Já o algoritmo de Harris-Stephens para detecção de bordas (do inglês, *Harris-Stephens Corners Detector*) é uma solução mais simples que utiliza detecção de bordas e cantos para detecção de objetos. Para mais detalhes sobre esse algoritmo recomenda-se a leitura do artigo “A combined corner and edge detector - (HARRIS; STEPHENS, 1988)”.

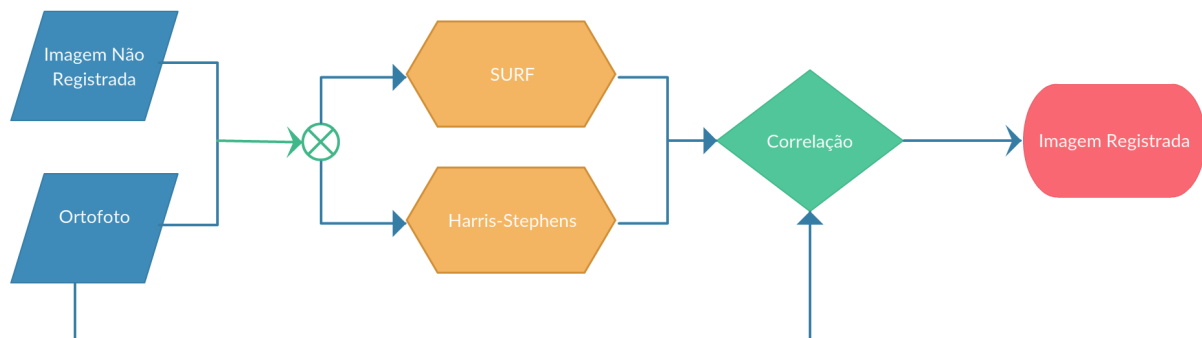


Figura 3.5.1 – Registro Automático de Imagem

O algoritmo automático para registro de imagens está ilustrado na Fig. 3.5.1. Primeiramente a imagem não registrada passa pelo processo de registro utilizando tanto o algoritmo *SURF* quanto o algoritmo de Harris-Stephens. Ao final desse processo têm-se duas imagens registradas, porém apenas uma será utilizada. A seleção da imagem final é feita a partir da correlação entre as imagens registradas na etapa anterior com a Ortofoto utilizada. A imagem com maior correlação é selecionada como o produto final desse algoritmo automático para registro de imagens.

3.6 Calibração Radiométrica

Em sensoriamento remoto é de extrema importância extrair, das imagens, informações físicas e mensuráveis como radiância ou reflectância. Porém, as imagens digitais (em formato matricial) representam geralmente apenas números digitais adimensionais, valores de intensidade de cinza (do inglês, *grey level*). Com isso, a Calibração Radiométrica tem como objetivo principal converter os números digitais das imagens em radiância, reflectância ou temperatura.

Nesse trabalho a calibração radiométrica foi feita a partir do cálculo da reflectância no topo da atmosfera (do inglês, *Top of Atmosphere Reflectance* - ToA Reflectance).

$$\rho_\lambda = \frac{\pi \cdot L_\lambda \cdot d^2}{ESUN_\lambda \cdot \cos(\theta)} \quad (3.1)$$

$$L_\lambda = Gain_\lambda \cdot DN + Offset_\lambda \quad (3.2)$$

As equações 3.1 e 3.2 representam o cálculo da Reflectância (ρ_λ) [$W/(m^2 \cdot sr \cdot \mu m)$] para cada banda espectral. Nas expressões, π representa a contante matemática, L_λ a radiância espectral [$W/(m^2 \cdot sr \cdot \mu m)$], " d " representa a distância Sol-Terra em unidades astronômicas [UA], θ corresponde ao ângulo zenital solar [rad] e DN o nível digital do pixel de cada imagem. $ESUN_\lambda$, $Gain_\lambda$ e $Offset_\lambda$ são constantes pré-definidas para cada sensor, onde $ESUN_\lambda$ representa a irradiância solar exoatmosférica média no topo da atmosfera [$W/(m^2 \cdot \mu m)$].

Para o caso CBERS4/MUX, as contantes $ESUN_\lambda$, $Gain_\lambda$ e $Offset_\lambda$ estão ilustradas na Tab. 3.6.1. Tais constantes foram utilizadas de acordo com a calibração radiométrica feita por Pinto (2016). Já a distância Sol-Terra e o ângulo zenital solar são variáveis em função do tempo, portanto elas mudam de acordo com a data em que cada imagem foi adquirida. Esses dados podem ser encontrado no metadado ao fazer o download das imagens.

Tabela 3.6.1 – Calibração Radiométrica CBERS4/MUX (Fonte: Pinto (2016))

Bandas	$ESUN_\lambda$	$Gain_\lambda$	$Offset_\lambda$
5 - Blue	1958.00	1.69	0.00
6 - Green	1852.00	1.61	0.00
7 - Red	1559.00	1.57	0.00
8 - NIR	1091.00	1.40	0.00

Para o caso Landsat8/OLI, o cálculo da Reflectância ToA ($\rho_{\lambda,Toa}$) foi bastante simples e está descrito nas equações 3.3 e 3.4.

$$\rho_\lambda = Gain_\lambda \cdot DN + Offset_\lambda \quad (3.3)$$

$$\rho_{\lambda, Toa} = \frac{\rho_\lambda}{\cos(\theta)} \quad (3.4)$$

As constantes $Gain_\lambda$ e $Offset_\lambda$ estão ilustradas na Tab. 3.6.2 e foram utilizadas de acordo com o manual do usuário do Satélite Landsat 8 (USGS, 2017). Já o ângulo zenital solar, que é uma variável em função do tempo, pode ser encontrado no metadado das imagens ao fazer o download delas. Tal valor varia de acordo com a data em que cada imagem foi adquirida.

Tabela 3.6.2 – Calibração Radiométrica Landsat8/OLI (Fonte: USGS (2017))

Bandas	$Gain_\lambda$	$Offset_\lambda$
1 a 9	2.0E-05	-0.10


3.7 Máscaras

3.7.1 Landsat8/OLI


Para o caso Landsat8/OLI duas máscaras foram utilizadas, são elas: *Fmask* e Banda de qualidade (BQA). Ambas as máscaras têm o objetivo de retirar pixels indesejados como nuvens e sombras de nuvens.

A Fig. 3.7.1 (b) ilustra o desempenho do algoritmo Fmask para detecção de nuvens e sombras de nuvens. *Fmask* é um algoritmo automático, e *open-source*, que gera máscaras de nuvens e sombras de nuvens (ZHU; WANG; WOODCOCK, 2015). Nesse projeto foi utilizado a versão 3.3.0 para *Matlab* desse algoritmo, que utiliza nove bandas espectrais (Banda 1 a 9) para a construção das máscaras.


A banda de qualidade da plataforma Landsat8/OLI (BQA), ilustrada na Fig. 3.7.1 (c), é uma banda adicional, onde seu download pode ser feita em conjunto com as bandas espectrais desse sensor. Essa banda traz informações extras sobre a qualidade cada pixel das cenas Landsat8/OLI, como presença de nuvem, neve e água.



(a) Landsat 8 - OLI - RGB



(b) algoritmo Fmask



(c) Landsat 8 - Banda de Qualidade

Figura 3.7.1 – Fmask algoritmo - Nuvens e Sombra de Nuvens

Na Fig. 3.7.1 (a) ilustrada a composição RGB da Fazenda Água Limpa (FAL) para o dia 19 de Julho de 2015. Como pode ser observado, os pixels da banda de Qualidade que representam nuvens (em vermelho) possuem valor muito maior que os pixels “limpos” (em azul).

A construção da máscara de pixels “limpos” utilizando a Banda BQA é composta de três etapas, são elas: Limiar (do inglês, *Threshold*), Erosão e Dilatação. A Fig. 3.7.2 ilustra esquematicamente esse processo de construção da máscara de pixels “Limpos”.

Para o Limiar, pixels da Banda BQA com valor maior ou igual a 20480 e menor ou igual a 23105 são selecionados como pixels limpos, enquanto o resto é considerado como pixels indesejados.





Figura 3.7.2 – algoritmo da Máscara Banda BQA

Já Erosão e Dilatação são operações morfológicas utilizadas com bastante frequência em Sensoriamento Remoto. Nesse sentido, a Erosão tem como objetivo remover pixels isolados, enquanto a Dilatação busca preencher possíveis buracos e alargar a área onde há presença de nuvens.

As Figuras 3.7.3 (a), (b) e (c) ilustram os resultados após os processos de Limiar, Erosão e Dilatação, respectivamente. Observando-se as Figuras 3.7.3 (b) e (c), nota-se que as operações morfológicas cumpriram com seus objetivos, remover pixels isolados e alargar a áreas onde há presença de nuvens. Com isso, a máscara ilustrada na Fig. 3.7.3 (c) é somada com a máscara produzida pelo algoritmo *Fmask*, ilustrada na Fig. 3.7.1 (b), para composição de uma só máscara.

A máscara final está representada na Fig. 3.7.3 (d), onde os pixels em branco representam os pixels indesejados enquanto os em preto representam os pixels “limpos”. Nesse sentido, caso seja calculado índices para as regiões em branco da máscara final, esses índices serão descartados já que representam pixels de nuvens, em vez de campos de murundus.



(a) Limiar



(b) Erosão



(c) Dilatação



(d) Máscara Final

Figura 3.7.3 – Construção de Máscara - Landsat 8/Oli

3.7.2 CBERS 4/ MUX

Como no caso CBERS 4 não há algoritmos prontos, como o algoritmo Fmask, nem banda de qualidade, como no caso Landsat 8, foi necessário portanto a construção de uma rotina que fosse capaz de detectar nuvens e sombras de nuvens utilizando as imagens multi-espectrais do satélite CBERS 4.

Tal rotina foi desenvolvida a partir de trabalhos anteriores, tais como *CBERS-4/MUX automatic detection of clouds and cloud shadows using decision trees* (SANTOS; BENDINI,) e Detecção Automática de Nuvem e Sombra de Nuvem em Imagens de Sensoriamento Remoto (SILVA; LIPORACE, 2016).

O código desenvolvido baseia-se em uma sequência de limiares (do inglês, threshold) das bandas espectrais do Azul, Verde, Vermelho e Infravermelho Próximo (NIR) e dos seguintes índices: *NDVI*, *SAVI*, *HOT*, *SOT*, *CSVI* e *WI*. Os índices *NDVI* e *SAVI* já foram introduzidos anteriormente na seção 2.2.3 como o Índice de Vegetação da Diferença Normalizada e o Índice de Vegetação Ajustado ao Solo, respectivamente.

O índice *HOT* (do inglês, *Haze Optimized Transformation*), inicialmente utilizado para detecção de nuvens e neblinas para a missão Landsat (YANG; ZHENG; CHEN, 2015), é calculado por meio da banda do azul e do vermelho, como mostrado na equação 3.5.

$$HOT = Azul - 0.45 \cdot Vermelho - 0.07 \quad (3.5)$$

As Figuras 3.7.4 e 3.7.5 ilustram a composição RGB e o comportamento do índice *HOT* para o sensor CBERS 4/MUX, respectivamente. Tal área corresponde a cidade-satélite Gama do Distrito Federal, região essa em que se encontra o Campus FGA da Universidade de Brasília. Observando-se a Fig. 3.7.4, percebe-se a presença de nuvens (em branco) em diversas áreas da imagem.



Figura 3.7.4 – RGB - Cbers 4 / MUX

Observando-se a Fig. 3.7.5, percebe-se que o *HOT* possui valor maior que zero para áreas onde há presença de nuvens e valores menor que zero para as demais áreas. Para nuvens mais densas, esse índice pode atingir valores acima de 0.2.




Figura 3.7.5 – HOT - Cbers 4 / MUX

Já os índices *SOT* e *CSV* foram desenvolvidos no presente trabalho. O *SOT* (do inglês, *Shadow Optimized Transformation*) representa uma variação do *HOT*, com o propósito de detectar sombras de nuvens. Para calcular tal índice, é utilizado a banda do vermelho e a do infravermelho próximo (NIR), como mostrado na equação 3.6.

$$SOT = 1.75 \cdot NIR - Vermelho - 0.13 \quad (3.6)$$

A Fig. 3.7.6 ilustra o comportamento do índice *SOT* para o sensor MUX. Como pode ser visto, tal índice possui valor menor que zero para áreas onde há presença de sombras de nuvens.




Figura 3.7.6 – SOT - Cbers 4 / MUX

O índice *CSV* (do inglês, *Combined Soil-Vegetation Index*), calculado pela equação 3.7 e ilustrado na Fig. 3.7.7, demonstrou ser uma boa ferramenta para detecção de nuvens e sombras de nuvens. Observado-se a equação 3.7 nota-se que o *CSV* é calculado a partir de dois outros índices, *NDVI* (eq. 2.1) e *SAVI* (eq. 2.2).

$$CSV = \frac{SAVI - NDVI}{SAVI + NDVI} \quad (3.7)$$




Figura 3.7.7 – CSVI - Cbers 4 / MUX

A Fig. 3.7.7 ilustra o comportamento do índice *CSVI* para o sensor MUX. Tal índice possui valores acima de -0.2 para regiões onde há presença de nuvens e valores abaixo de -0.4 para áreas com sombra de nuvens.

Já o índice WI (do inglês, *Whiteness Index*), originalmente proposto por (GÓMEZ-CHOVA et al., 2007) e também utilizado no algoritmo *Fmask* (ZHU; WANG; WOODCOCK, 2015), foi desenvolvido principalmente para detecção de nuvens em Sensoriamento Remoto. No presente trabalho tal índice foi modificado para que fosse capaz de detectar sombras de nuvens.

O cálculo do WI é feito em duas etapas, ilustradas pelas equações 3.8 e 3.9. Primeiramente calcula-se uma média ponderada (M) entre as bandas do espectro visível, são elas: bandas espectrais do azul, verde e vermelho. Posteriormente, WI é calculado como a diferença absoluta e normalizada entre a banda azul e a média “ M ” (3.9).

$$M = 0.250 \cdot Azul + 0.375 \cdot Verde + 0.375 \cdot Vermelho \quad (3.8)$$

$$WI = \left| \frac{Azul - M}{M} \right| \quad (3.9)$$

A Fig. 3.7.8 representa o WI calculado para a região da Fig. 3.7.4. Como pode ser observado, as sombras de nuvens se destacam ao se utilizar tal índice, tendo um valor médio de WI maior que 0.1.




Figura 3.7.8 – WI - Cbers 4 / MUX

Após a construção de todos índices mencionados, e utilizando a reflectância das bandas do azul, verde, vermelho e infravermelho, foi possível desenvolver um algoritmo para detecção de nuvens e sombras de nuvens para o sensor CBERS 4 -MUX. As Figuras 3.7.9 e 3.7.10 exemplificam os algoritmos para detecção de nuvens e sombras, respectivamente.

Para caracterização de nuvens, ilustrada na Fig. 3.7.9 e na Tab. 3.7.1, apenas cinco limiares (do inglês, *Threshold*) são utilizados.

Tabela 3.7.1 – Limiares: Máscara de Nuvens - CBERS4/MUX

Banda 1 (Azul)	maior ou igual a 0.11
Banda 2 (Verde)	maior ou igual a 0.10
Banda 4 (NIR)	maior ou igual a 0.24
<i>CSV</i>	maior ou igual a -0.26
<i>HOT</i>	maior ou igual a 0.00

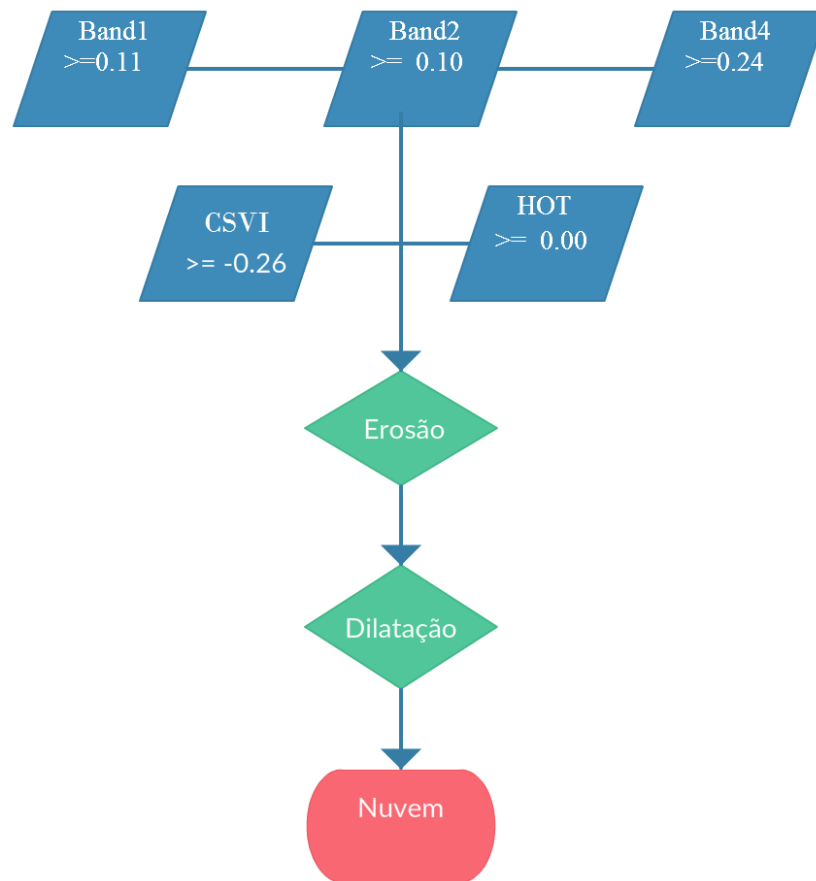


Figura 3.7.9 – Máscara de Nuvens - Cbers 4 / MUX

Já para o caso de detecção de sombras, ilustrado na Fig. 3.7.10 e na Tab. 3.7.2, sete limiares são utilizados.

Tabela 3.7.2 – Limiares: Máscara de Sombras - CBERS4/MUX

Banda 1 (Azul)	menor ou igual a 0.12
Banda 2 (Verde)	menor ou igual a 0.10
Banda 3 (Vermelho)	menor ou igual a 0.10
Banda 4 (NIR)	menor ou igual a 0.12
<i>SOT</i>	menor ou igual a 0.00
<i>CSVI</i>	menor ou igual a -0.40
<i>WI</i>	maior ou igual a 0.20

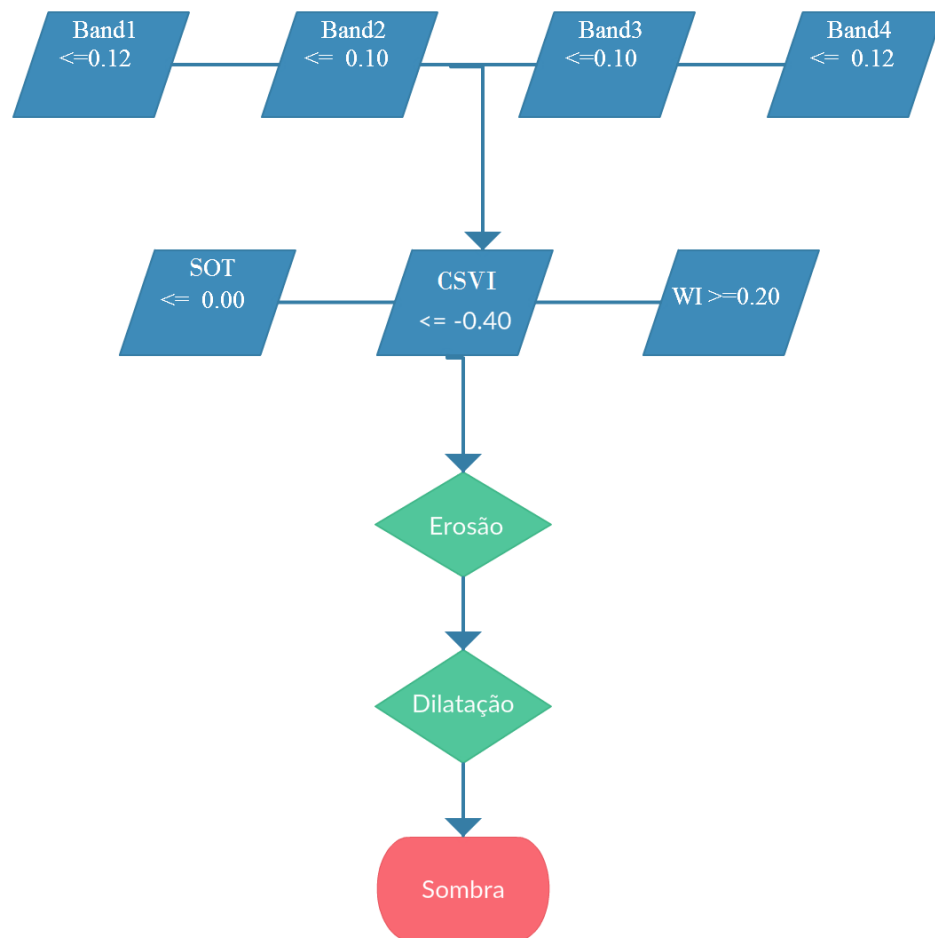



Figura 3.7.10 – Máscara de Sombras - Cbers 4 / MUX

Em ambos casos, as operações morfológicas de erosão e dilatação são utilizadas. Assim como no caso Landsat 8, a erosão tem o objetivo de remover pixels isolados, enquanto a dilatação busca preencher possíveis buracos e alargar a área onde há presença de nuvens e sombras.

A Fig. 3.7.11 ilustra o algoritmo aplicada para uma imagem obtida pelo sensor MUX. A imagem teste foi obtida no dia 27/12/2016 no território de Brasília e conseguiu validar os algoritmos de detecção de nuvens e sombras explicados neste trabalho.



(a) Imagem Original



(b) Máscara - Cbers 4 / MUX

Figura 3.7.11 – Construção de Máscara - Landsat 8/Oli

3.8 Geração de Índices

As Figuras 3.8.1 a 3.8.6 representam o comportamento temporal, entre os anos de 2015 a 2017, dos Murundus das seguintes áreas: 1) Fazenda Água Limpa - FAL, 2) UnB/Gama - FGA, 3) Samambaia, 4) Floresta Nacional, 5) Parque Nacional e 6) Chapada Imperial, respectivamente.

Como dito anteriormente, três índices foram calculados para todas as áreas analisadas, são eles: NDVI, SAVI e NDWI. O primeiro está representado em cor verde, o segundo em vermelho e o terceiro em azul. As linhas tracejadas representam o sensor MUX – CBERS 4 enquanto as contínuas representam o sensor OLI – Landsat 8.




Figura 3.8.1 – FAL - 2015 a 2017




Figura 3.8.2 – FGA - 2015 a 2017




Figura 3.8.3 – Samambaia - 2015 a 2017




Figura 3.8.4 – Floresta Nacional - 2015 a 2017




Figura 3.8.5 – Parque Nacional - 2015 a 2017




Figura 3.8.6 – Chapada Imperial - 2015 a 2017

4 Resultados e Discussão

Observando-se as Figuras 3.8.1 a 3.8.6, foi notado quatro pontos principais para a análise dos Murundus do Cerrado:

- Diferença entre os valores absolutos dos índices para os diferentes sensores (OLI e MUX)
- Similaridade entre os índices NDVI e SAVI
- Relação inversamente proporcional entre o NDVI e o NDWI
- Comportamento sazonal de todos os índices

Até a presente data, Março de 2018, apenas foi encontrado uma única documentação oficial sobre calibração radiométrica para o sensor MUX. Tal calibração foi feita em março de 2015 (PINTO, 2016), o que corresponde a três anos sem calibração desse sensor. Podem haver outras calibrações recentes para o sensor MUX, porém apenas a documentação de Pinto (2016) foi encontrada.

Além disso, para a calibração do sensor MUX, Pinto (2016) utilizou imagens do Satélite Landsat 7. Porém, para o presente trabalho, foram utilizadas imagens do Satélite Landsat 8 (OLI). Fato esse que também pode explicar a diferença entre os índices produzidos pelos sensores OLI e MUX.

Os índices NDVI e SAVI apresentaram comportamento similar, fato esse que não era esperado. A similaridade desses índices é algo indesejado para esse trabalho, já que não traz informações adicionais sobre as áreas examinadas. Com isso, apenas os índices NDVI e NDWI foram utilizados para a análise dos Murundus do Cerrado, descartando, portanto, o SAVI.

Outro fato interessante foi o comportamento sazonal dos índices, onde todos eles mostraram estar relacionados com a curva de precipitação de chuva de Brasília, ilustrada na Fig. 4.0.1.




Figura 4.0.1 – Precipitação Média de Chuva de Brasília
(Fonte: <https://pt.climate-data.org/location/852/>)

O NDVI demonstrou estar diretamente proporcional a curva de precipitação, enquanto o NDWI teve um comportamento inversamente proporcional a essa curva. Tal comportamento era esperado, já que em períodos de chuva, quando a vegetação está saudável pela presença de água no solo, o NDVI apresenta valor alto e o NDWI tem valor baixo. Já em períodos de seca, quando a vegetação sofre estresse hídrico, o NDVI assume valores baixos enquanto o NDWI assume valores elevados.

As Figuras 4.0.2 e 4.0.3 ilustram o comportamento do NDVI e NDWI para todas as seis áreas estudadas utilizando os sensores OLI e MUX, respectivamente.




Figura 4.0.2 – NDVI e NDWI: OLI - 2015 a 2017




Figura 4.0.3 – NDVI e NDWI: MUX - 2015 a 2017

Analisando as Figuras 4.0.2 e 4.0.3, observou-se que campos de murundus não preservados, como os da FGA e de Samambaia, apresentaram valores muito baixos de

NDVI e muito altos de NDWI para períodos de seca.

Observando-se a Fig. 4.0.2, por exemplo, entre Agosto e Setembro de 2015, tais áreas atingiram valores de NDVI menor que 0.3 e NDWI maior que -0.3, utilizando o sensor OLI.

Para o sensor MUX, Fig. 4.0.3, entre o mesmo período de Agosto a Setembro de 2015, tais áreas atingiram valores de NDVI menor que 0.25 e NDWI maior que -0.25. Tal comportamento não pode ser observado em áreas de preservação, tais como os campos de murundus do Parque Nacional e da Floresta Nacional.

Visando estimar quando os Murundus do Distrito Federal estão saudáveis e quando eles estão sofrendo estresse hídrico, foram utilizados valores de referência tanto para o NDVI quanto para o NDWI. Esses valores estão ilustrados na Tab. 4.0.1.

Tabela 4.0.1 – Valores de Referência para Murundus Saudáveis

	OLI	MUX
NDVI (maior ou igual)	0.50	0.42
NDWI (menor ou igual)	-0.45	-0.35

Valores de NDVI acima da referência foram considerados como vegetação saudável e valores abaixo como não saudável. Como o NDWI possui comportamento oposto ao NDVI, valores abaixo do NDWI de referência foram considerados como vegetação saudável e valores acima como não saudável.

Os limiares representados na Tab. 4.0.1 estão ilustrados como linhas contínuas (em cor verde-escuro) nas Figuras 4.0.2 e 4.0.3. Esses valores podem variar dependendo da densidade de vegetação e do tipo de vegetação estudado. Portanto, para monitoramento dos murundus de outras áreas (que não sejam do cerrado, por exemplo), os valores de referência da Tab. 4.0.1 podem não ser adequados.

Utilizando os limiares da Tab. 4.0.1, foi possível quantificar o período de estresse hídrico para cada região de interesse. A Tabela 4.0.2 ilustra tanto o intervalo temporal, quanto a quantidade de dias em que cada área estudada passou por estresse hídrico durante os anos de 2015 a 2017.

Tabela 4.0.2 – Período de Estresse Hídrico dos Murundus do Distrito Federal

Área	2015		2016	
	Período	Total*	Período	Total*
Parque Nacional	05/07 a 01/12	149	25/06 a 31/12	189
Floresta Nacional	25/05 a 31/12	220	20/03 a 31/12	286
Chapada Imperial	10/06 a 31/12	204	15/05 a 31/12	230
Fazenda Água Limpa - FAL	05/06 a 20/12	198	01/04 a 15/12	258
Samambaia	15/06 a 20/12	188	05/05 a 31/12	240
UnB/Gama - FGA	01/07 a 15/12	167	15/05 a 05/12	204

Área	2017	
	Período	Total*
Parque Nacional	05/07 a 31/12	179
Floresta Nacional	01/05 a 31/12	244
Chapada Imperial	01/05 a 31/12	244
Fazenda Água Limpa - FAL	15/05 a 31/12	230
Samambaia	01/06 a 25/12	207
UnB/Gama - FGA	15/05 a 01/12	200

* Total calculado em dias

Para a elaboração da Tab. 4.0.2, foi necessário fazer interpolação dos dados ilustrados nas Figuras 4.0.2 e 4.0.3. A interpolação foi feita por meio de ajustes de curvas (*Curve fitting*), tanto retas quando ondas senoidais.

De acordo com a Tab. 4.0.2, o ano de 2016 foi o pior ano para os murundus do DF. Observando - se a coluna “Total” dessa mesma tabela, nota-se que o ano 2016 teve o maior período de estresse hídrico para todas as áreas examinadas, com a exceção da região da Chapada Imperial. Para essa região em específico, o pior ano foi 2017.

Ao observar a Fig. 3.8.6 para o período, entre setembro e outubro de 2017, é possível notar que a região da Chapada Imperial teve uma queda brusca no valor do NDVI. Tal queda não pode ser observada nos demais anos, o que justifica o agravamento dos índices dessa região para o ano de 2017. Além disso, durante esse período entre setembro e outubro de 2017, a Chapada Imperial teve focos de incêndios próximos aos campos de murundus estudados. Portanto, este é mais um indício da razão do ano 2017 ser o pior ano para essa região.

Como dito anteriormente, foi preciso fazer interpolação dos índices obtidos para a construção da Tab. 4.0.2. A interpolação foi necessária devido a falta de dados em alguns meses do ano, por exemplo, de Novembro a Fevereiro. Nesses meses, para a cidade de Brasília, boa parte das áreas examinadas possuíam uma alta concentração de nuvens ou sombras de nuvens (por exemplo, Cobertura de Nuvem maior que 50% da área de estudo). Portanto, não foi possível utilizar os índices dessas áreas, já que o sistema de

monitoramento proposto utiliza sensores ópticos.

Por os sensores ópticos não conseguirem penetrar as nuvens, devido ao comprimento de onda utilizado para faixa espectral óptica, o sistema de monitoramento proposto fica limitado a cobertura de nuvem. Portanto, caso queira monitorar áreas com densa quantidade de nuvens é recomendado a utilização de imagens radar.

Além disso, o algoritmo para construção de máscaras de nuvens e sombra desenvolvido para o sensor MUX, ilustrados nas Figuras 3.7.9 e 3.7.10, demonstrou não ser muito eficiente para detecção de nuvens do tipo Cirrus. Por serem nuvens aparentemente mais finas, em relação aos demais tipos de nuvens, as nuvens Cirrus não foram detectadas corretamente pelo algoritmo apresentado.

5 Conclusões

Seis áreas do Distrito Federal com presença de Campos de Murundus foram escolhidas para estudo nessa tese, são elas: Fazenda Aguá Limpa – UnB (FAL), Campus Gama da Universidade de Brasília (FGA), Samambaia, Floresta Nacional de Brasília, Parque Nacional de Brasília e Chapada Imperial.

O sistema de monitoramento proposto para essas regiões mostrou ser capaz de realizar seu trabalho de maneira adequada. Porém, para períodos durante os quais existem alta densidade de nuvens, recomenda-se a utilização de sistema radar em vez sistema óptico. O software *EcoTool* demonstrou ser um sistema robusto que suporta tanto dados Landsat 8 (OLI) quanto CBERS 4. Por meio das reflectâncias das bandas espectrais das duas plataformas satelitais, três índices de vegetação foram gerados, são eles: NDVI, SAVI e NDWI. Analisando esses índices durante o período entre 2015 a 2017, foi possível concluir quatro pontos principais sobre os Campos de Murundus do DF:

- Existem diferenças entre os valores absolutos dos índices para os diferentes sensores (OLI e MUX),
- A utilização do SAVI demonstrou ser irrelevante para o monitoramento dos Campos de Murundus,
- O NDVI e o NDWI apresentaram comportamentos proporcionais a quantidade de chuva acumulada no DF,
- Todos os índices apresentaram comportamento sazonal.

A diferença absoluta dos valores obtidos pelos sensores OLI e MUX tem como justificativa a calibração desse último sensor. Até a presente data, Março de 2018, apenas a calibração radiométrica feita por [Pinto \(2016\)](#) foi encontrado na literatura. Tal calibração foi feita em março de 2015 e foram utilizadas imagens Landsat 7 para o processo de calibração. Entretanto, o presente trabalho utilizou imagens Landsat 8 (OLI) para o sistema de monitoramento. Além disso, três anos sem calibração do sensor MUX pode ser outra justificativa para diferença de valores obtidos pelos sensores OLI e MUX.

Para todas as seis áreas de estudo, os índices SAVI e NDVI se comportaram de maneira semelhante, comportamento esse não esperado previamente. Quando o NDVI estava em alta, o SAVI apresentava um crescimento. Por outro lado, quando o NDVI estava em baixa, o SAVI apresentava decréscimo em seus valores. O comportamento semelhante desses índices não acrescentou informação adicional sobre as áreas de estudo,

portanto um desses índices foi descartado. Portanto, o SAVI foi descartado e o NDVI foi mantido para o sistema de monitoramento.

Com o SAVI descartado, foram utilizados apenas dois índices para o sistema de monitoramento, são eles: NDVI e NDWI. Com isso, o índice de vegetação (NDVI) apresentou comportamento inversamente proporcional ao índice de água (NDWI). Quando um estava em alta, o outro estava em baixa. Além disso, o NDVI demonstrou ter comportamento diretamente proporcional a quantidade de chuva acumulada no DF, enquanto o NDWI demonstrou ter comportamento inversamente proporcional.

Por fim, como dito acima, os índices de vegetação e de água estão relacionados com o a precipitação média de chuva de Brasília. Porém, a quantidade de chuva acumulada no DF, ilustrada na Fig. 4.0.1, possui comportamento sazonal. Portanto, tanto o NDVI quanto o NDWI apresentaram comportamento sazonal.

Referências

- ANTUNES, P. D. et al. Caracterização físico-química de micro-relevo de montículos “murundus” na região de janaúba no norte de minas gerais. *Revista Geonomos*, v. 20, n. 1, 2012. Citado na página 23.
- BAPTISTA, G. de M.; CORRÊA, R. S.; SANTOS, P. F. dos. Campos de murundus da fazenda água limpa da unb: hipóteses de origem. *Revista do CEAM*, n. 1, p. 47, 2013. Citado 2 vezes nas páginas 22 e 23.
- BAY, H. et al. Speeded-up robust features (surf). *Comput. Vis. Image Underst.*, Elsevier Science Inc., New York, NY, USA, v. 110, n. 3, p. 346–359, jun. 2008. ISSN 1077-3142. Disponível em: <<http://dx.doi.org/10.1016/j.cviu.2007.09.014>>. Citado na página 55.
- CAMPBELL, J. B.; WYNNE, R. H. *Introduction to remote sensing*. [S.l.]: Guilford Press, 2011. Citado 4 vezes nas páginas 26, 27, 31 e 35.
- CROSTA, A. P. *Processamento digital de imagens de sensoriamento remoto*. [S.l.]: UNICAMP/Instituto de Geociências, 2002. v. 4. Citado 2 vezes nas páginas 27 e 29.
- GAO, B.-C. Ndwí—a normalized difference water index for remote sensing of vegetation liquid water from space. *Remote sensing of environment*, Elsevier, v. 58, n. 3, p. 257–266, 1996. Citado na página 33.
- GÓMEZ-CHOVA, L. et al. Cloud-screening algorithm for envisat/meris multispectral images. *IEEE Transactions on Geoscience and Remote Sensing*, IEEE, v. 45, n. 12, p. 4105–4118, 2007. Citado na página 64.
- GONZALEZ, R. C.; WOODS, R. E. *Processamento digital de imagens*. [S.l.]: Pearson Prentice Hall, 2010. Citado na página 27.
- GUERRA, A. T. *Dicionário geológico, geomorfológico*. [S.l.]: Secretaria de Planejamento e Coordenação da Presidência da República, Fundação Instituto Brasileiro de Geografia e Estatística, 1993. Citado na página 19.
- HARRIS, C.; STEPHENS, M. A combined corner and edge detector. In: *In Proc. of Fourth Alvey Vision Conference*. [S.l.: s.n.], 1988. p. 147–151. Citado na página 55.
- HEWLETT, J. D.; HIBBERT, A. R. Moisture and energy conditions within a sloping soil mass during drainage. *Journal of geophysical research*, Wiley Online Library, v. 68, n. 4, p. 1081–1087, 1963. Citado 3 vezes nas páginas 8, 21 e 22.
- HORTON, R. E. The role of infiltration in the hydrologic cycle. *Eos, Transactions American Geophysical Union*, Wiley Online Library, v. 14, n. 1, p. 446–460, 1933. Citado na página 20.
- HUETE, A. R. A soil-adjusted vegetation index (savi). *Remote sensing of environment*, Elsevier, v. 25, n. 3, p. 295–309, 1988. Citado na página 32.
- JR, J. R. et al. Monitoring vegetation systems in the great plains with erts. 1974. Citado na página 31.

- JÚNIOR, P. R. de C. *Dinâmica da água em campos de murundus do Planalto dos Parecis*. Tese (Doutorado) — Universidade de São Paulo, 2002. Citado na página 22.
- LINTZ, J.; SIMONETT, D. *Remote Sensing of Environment*, Addison V. [S.l.]: esley Publishing Company Inc, 1976. Citado na página 26.
- MATHEWS, A. Studies on termites from the mato grosso state, brazil. academia brasileira de ciências. *Rio de Janeiro, Brazil*, 1977. Citado 2 vezes nas páginas 17 e 23.
- MCFEETERS, S. K. The use of the normalized difference water index (ndwi) in the delineation of open water features. *International journal of remote sensing*, Taylor & Francis, v. 17, n. 7, p. 1425–1432, 1996. Citado na página 34.
- MENESES, P. R. et al. Introdução ao processamento de imagens de sensoriamento remoto. *Brasília: UNB/CNPq*, 2012. Citado 3 vezes nas páginas 30, 48 e 55.
- NETO, M. A.; BAPTISTA, G. Recursos hídricos e ambiente. *Brasília: Edição do autor*, 1995. Citado na página 22.
- NETO, M. D. de A. *Solos, água e relevo dos campos de murundus na Fazenda Agua Limpa, distrito federal*. Tese (Doutorado) — Universidade de Brasília. Departamento de Biología Vegetal, 1981. Citado 3 vezes nas páginas 19, 24 e 50.
- NETO, M. D. de A. et al. The murundus of the cerrado region of central brazil. *Journal of Tropical Ecology*, Cambridge Univ Press, v. 2, n. 01, p. 17–35, 1986. Citado 2 vezes nas páginas 19 e 24.
- OLIVEIRA-FILHO, A. d.; FURLEY, P. Monchão, cocuruto, murundu. *Ciência Hoje*, v. 11, n. 61, p. 30–37, 1990. Citado na página 24.
- OLIVEIRA-FILHO, A. T. de. Floodplain ‘murundus’ of central brazil: evidence for the termite-origin hypothesis. *Journal of Tropical Ecology*, Cambridge Univ Press, v. 8, n. 01, p. 1–19, 1992. Citado 2 vezes nas páginas 19 e 23.
- PINTO, C. T. *Uncertainty evaluation for in-flight radiometric calibration of earth observation sensors*. Tese (Doutorado) — Instituto Nacional de Pesquisas Espaciais - INPE, 2016. Citado 4 vezes nas páginas 11, 56, 73 e 80.
- SANTOS, I. d. et al. Monitoramento e modelagem de processos hidrogeomorfológicos: mecanismos de geração de escoamento e conectividade hidrológica. Florianópolis, 2009. Citado na página 20.
- SANTOS, R. D. C. dos; BENDINI, H. do N. Cbers-4/mux automatic detection of clouds and cloud shadows using decision trees renman de freitas bezerra marujo1 leila maria garcia fonseca1 thales sehn korting1. Citado na página 61.
- SILVA, L. C. et al. Deciphering earth mound origins in central brazil. *Plant and Soil*, Springer, v. 336, n. 1-2, p. 3–14, 2010. Citado 2 vezes nas páginas 17 e 24.
- SILVA, M. A. Oliveira da; LIPORACE, F. dos S. Detecção automática de nuvem e sombra de nuvem em imagens de sensoriamento remoto. *Boletim de Ciências Geodésicas*, Universidade Federal do Paraná, v. 22, n. 2, 2016. Citado na página 61.

- USGS. *Using the USGS Landsat 8 Product @ONLINE*. 2017. Disponível em: <https://landsat.usgs.gov/using-usgs-landsat-8-product>. Citado 2 vezes nas páginas 11 e 57.
- XU, H. Modification of normalised difference water index (ndwi) to enhance open water features in remotely sensed imagery. *International journal of remote sensing*, Taylor & Francis, v. 27, n. 14, p. 3025–3033, 2006. Citado na página 35.
- YANG, Y.; ZHENG, H.; CHEN, H. Automated cloud detection algorithm for multi-spectral high spatial resolution images using landsat-8 oli. In: TAN, T. et al. (Ed.). *Advances in Image and Graphics Technologies*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2015. p. 396–407. ISBN 978-3-662-47791-5. Citado na página 61.
- ZHU, Z.; WANG, S.; WOODCOCK, C. Improvement and expansion of the fmask algorithm: Cloud, cloud shadow, and snow detection for landsats 4-7, 8, and sentinel 2 images. v. 159, 01 2015. Citado 2 vezes nas páginas 57 e 64.

Apêndices

APÊNDICE A – Rotina

GET_DATA_FROM_LINK.m

```

1 - restoredefaultpath;
2 - clear all;
3 - close all;
4 - clc;
5
6 - ORDER_NUMBER      = '1208181';      % Numero de Ordem
7 - LOGIN              = 'tccmurundus'; % Login no site do INPE
8
9
10 - DIRECTORY         = pwd();
11 - DOWNLOADS_DIRECTORY = strcat(DIRECTORY(1:end-8), 'Downloads');
12 - URL               = strcat('http://imagens.dgi.inpe.br/cdsr/', LOGIN, ORDER_NUMBER, '/');
13
14 - TXT_WGET          = strcat('wget -r -A ".txt"');
15 - ZIP_WGET          = strcat('wget -r -A ".zip"');
16 - TIF_ZIP_WGET      = strcat('wget -r -A ".tif.zip"');
17
18 % Arquivo cmd.txt
19 - fileID = fopen('cmd.txt', 'w');
20 - fprintf(fileID, ' %s %s\n', TXT_WGET, URL);
21 - fprintf(fileID, ' %s %s\n', ZIP_WGET, URL);
22 - fprintf(fileID, ' %s %s\n', TIF_ZIP_WGET, URL);
23 - fprintf(fileID, ' %s \n', 'exit');
24 - fprintf(fileID, ' %s \n', 'exit');
25 - fclose(fileID);
26
27 - NEW_FOLDER_DIRECTORY = strcat(DIRECTORY, '\', 'imagens.dgi.inpe.br');
28 - FILES_DIRECTORY      = strcat(NEW_FOLDER_DIRECTORY, '\', 'cdsr', '\', ...
29                               LOGIN, ORDER_NUMBER);
30
31 - [status] = dos('cmd < cmd.txt');
32 - if status == 0
33
34 -     fileID = fopen('delete_folder.txt', 'w');
35 -     fprintf(fileID, 'RD /S /Q "%s" \n', 'imagens.dgi.inpe.br');
36 -     fprintf(fileID, ' %s \n', 'exit');
37 -     fclose(fileID);
38
39 -     movefile(strcat(FILES_DIRECTORY, '/*'), DOWNLOADS_DIRECTORY);
40
41 -     dos('cmd < delete_folder.txt');
42 -     delete cmd.txt;
43 -     delete delete_folder.txt;
44
45 -     cd(DOWNLOADS_DIRECTORY)
46 - else
47 -     fprintf('\nERROR: Error while downloading files\n')
48 - end
49
50 - WarnWave = [sin(1:.6:400), sin(1:.7:400), sin(1:.4:400)];
51 - Audio = audioplayer(WarnWave, 22050);
52 - play(Audio);
53

```

Figura A.0.1 – Rotina *GET_DATA_FROM_LINK.m*

APÊNDICE B – EcoTool

A ferramenta *EcoTool*, ilustrada na Fig. B.0.1, foi toda desenvolvida em *Matlab* com o auxílio da interface gráfica *Guide*. Nessa ferramenta é possível realizar Georreferenciamento de Imagens, Registro de Imagens, Índices de Vegetação e Construção Automática de Máscaras de Nuvens e Sombras de Nuvens.

O funcionamento dessa plataforma se baseia em seis etapas:

- Criação de Projeto
- Importação de Imagens
- Criação de Banco de Dados
- Criação de Ortofoto
- Seleção de Região de Interesse
- Análise de Resultados

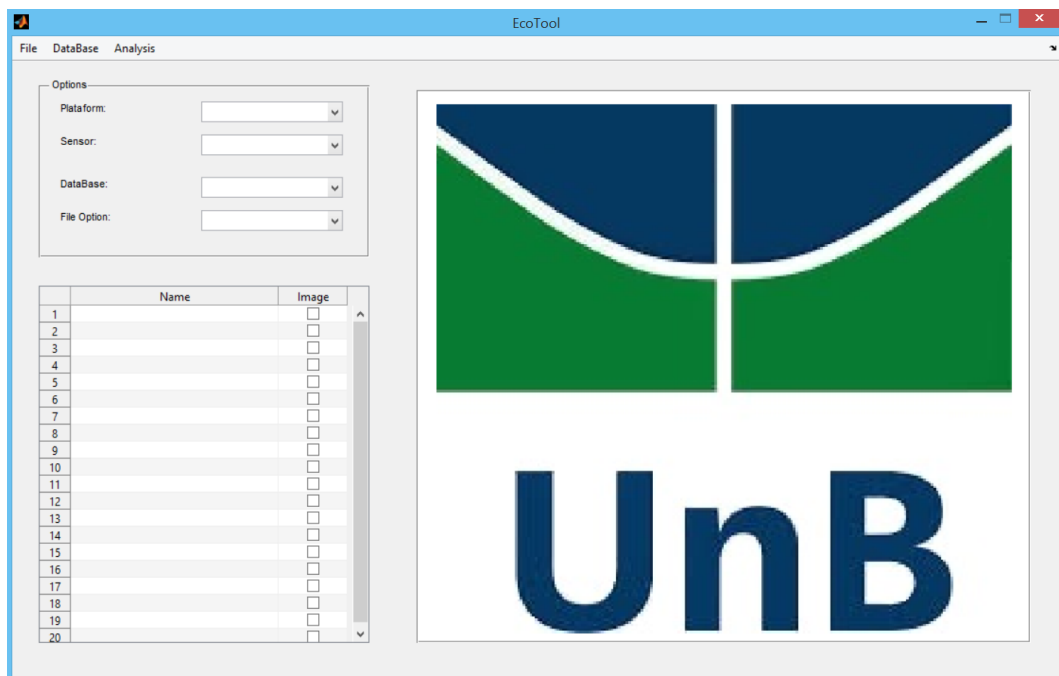


Figura B.0.1 – EcoTool

B.1 Criação de Projeto

Para se utilizar do software *EcoTool*, primeiramente é necessário criar um projeto. O processo de criação de projeto é bem simples. Primeiro vá na opção **File** e clique em **New Project** (Fig. B.1.1).

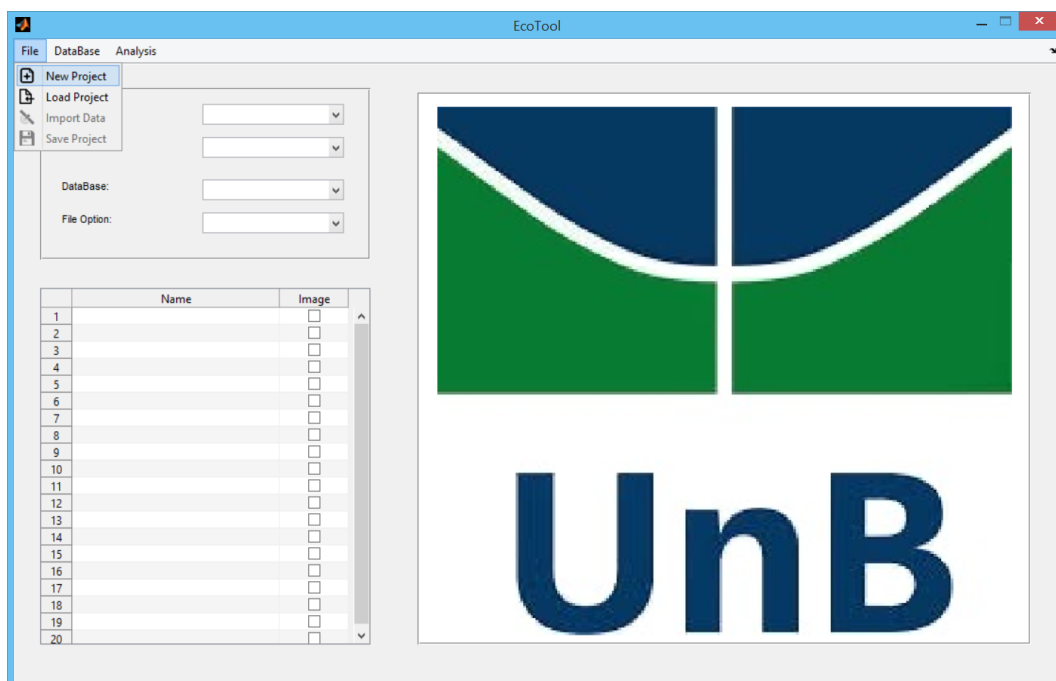


Figura B.1.1 – Criando Novo Projeto

Depois, escolha um nome para seu projeto e clique em ROI OK” (Fig. B.1.2).

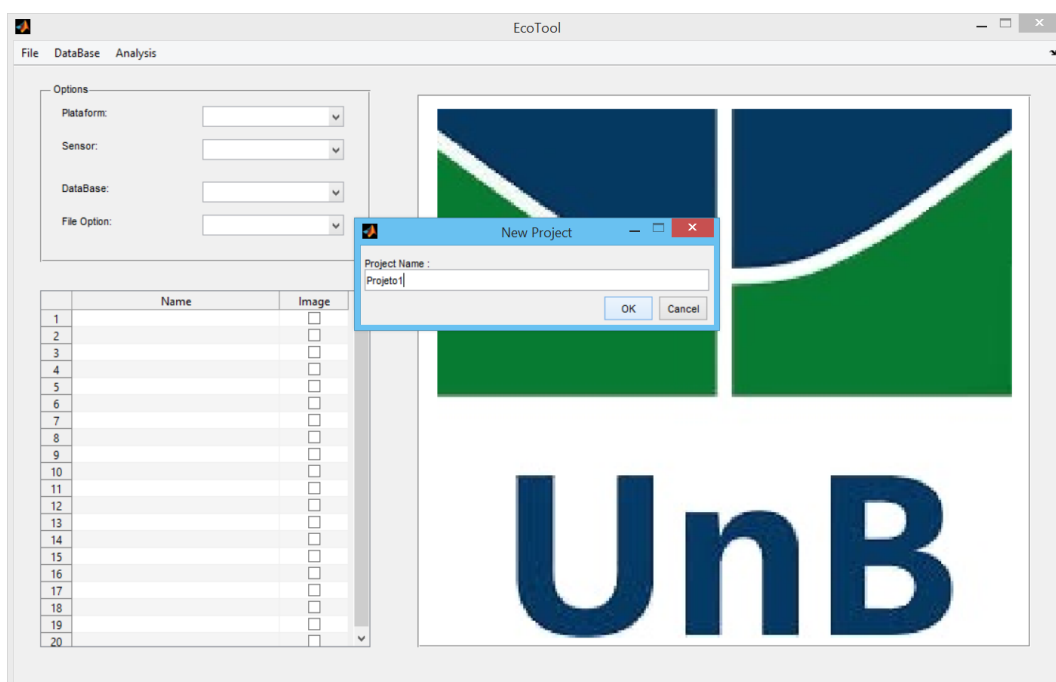


Figura B.1.2 – Nome do Novo Projeto

Por fim, selecione o diretório em que se deseja salvar seu projeto e clique em **Select Folder** (Fig. B.1.3).

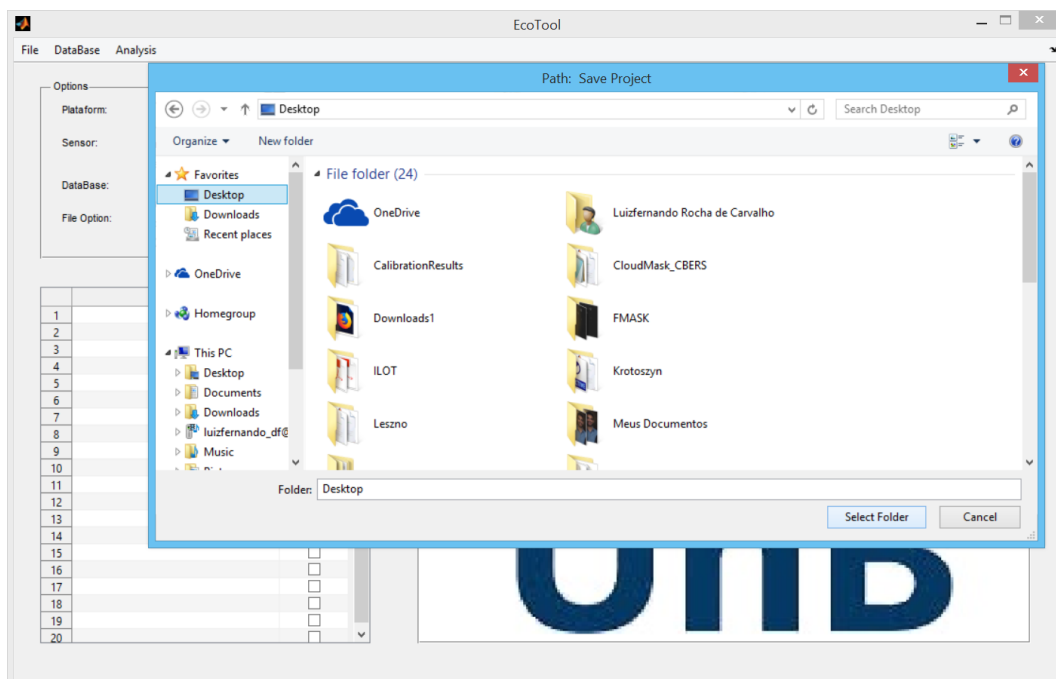


Figura B.1.3 – Diretório do Novo Projeto

Após a criação do novo projeto, salve seu projeto por meio das opções **File** e **Save** (Fig. B.1.2).

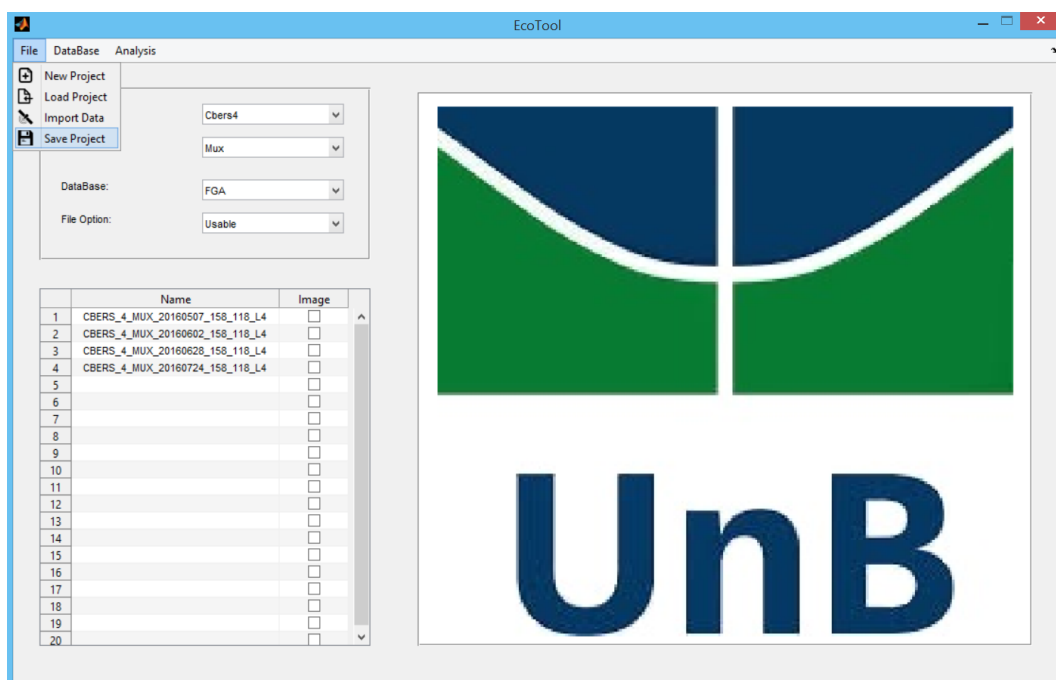


Figura B.1.4 – Salvando o Novo Projeto

Com o projeto salvo, é preciso importar as imagens a serem processadas.

B.2 Importação de Dados ao Projeto

EcoTool suporta tanto dados Landtat 8 (OLI) quanto CBERS 4 (MUX e PAN10m). É de extrema importância que os nomes originais dos dados não sejam alterados, portanto, ao fazer o download das imagens dessas duas plataformas, não alterem seus nomes. Além disso, também mantenha as imagens em seus formatos originais, ou seja, não descompacte elas.

Para importar dados ao projeto, vá nas opções **File** e **Import Data** (Fig. B.2.1).

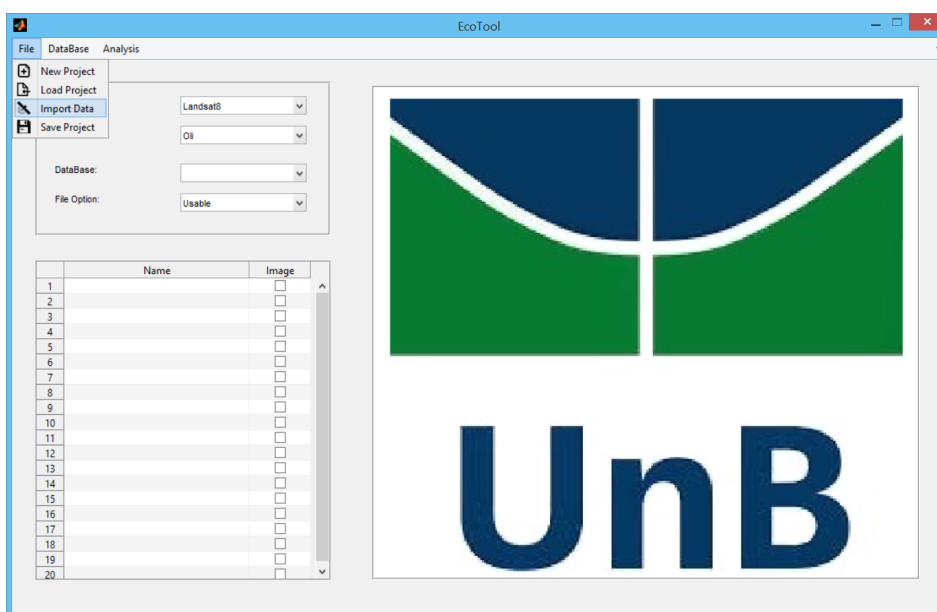


Figura B.2.1 – Importando Dados ao Projeto

Selecione a Plataforma utilizada e pressione **OK** (Fig. B.2.2).

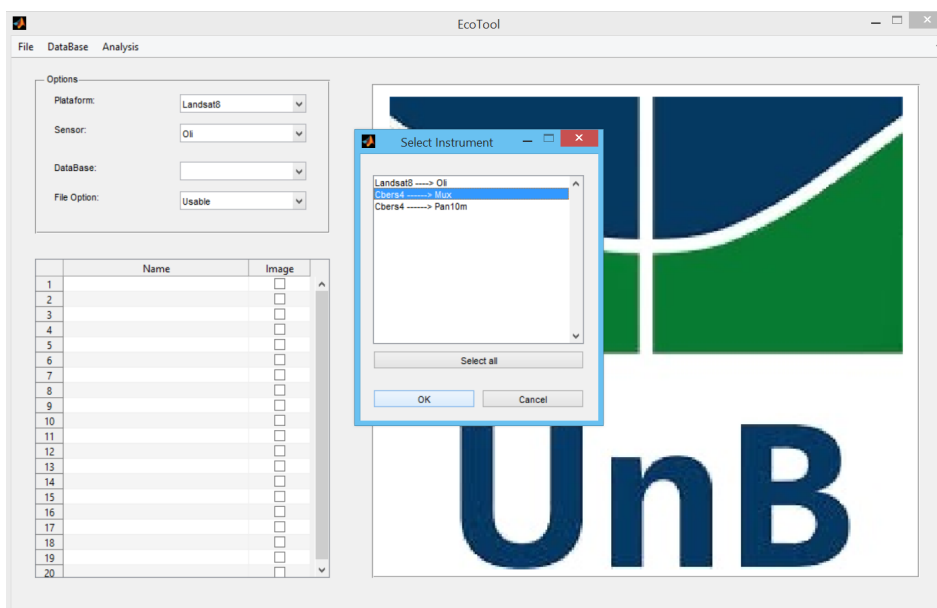


Figura B.2.2 – Selecionando Plataforma

Depois, selecione as imagens a serem processadas e clique em **Open** (Fig. B.2.3).




Figura B.2.3 – Selecionando Imagens

Uma janela aparecerá, ilustrada na Fig. B.2.4, perguntando se o usuário deseja mover todas as imagens ao projeto ou apenas copiá-las. É recomendado copiar as imagens para o projeto em vez de movê-las, assim as imagens originais permanecerão salvas em seus antigos diretórios.

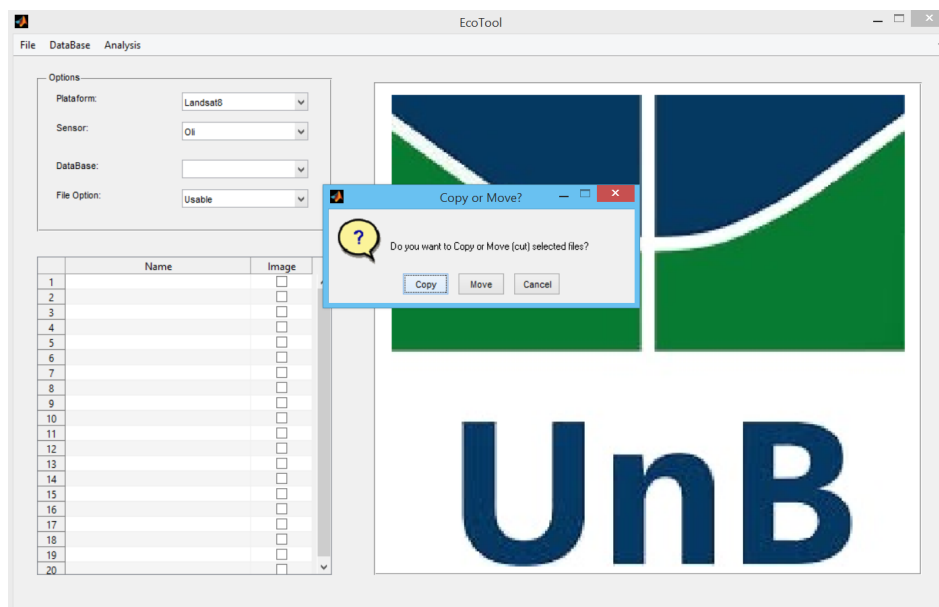


Figura B.2.4 – Copiar ou Mover

Por fim, todas as imagens selecionadas serão carregadas para o projeto. O processo de carregamento pode ser acompanhado pela barra de carregamento ilustrada na Fig. B.2.5.

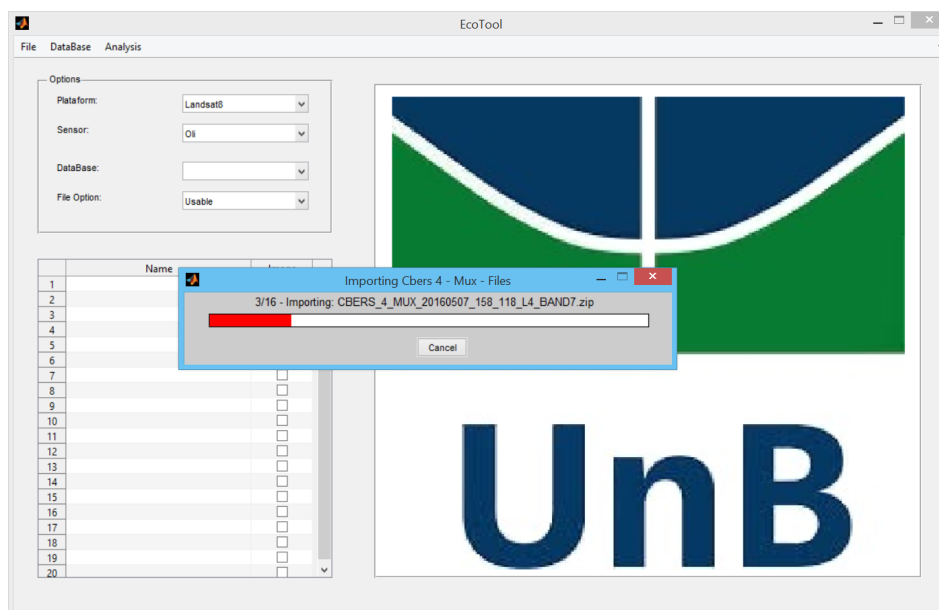


Figura B.2.5 – Carregando Imagens ao Projeto

Com o processo de importação completo, uma mensagem, ilustrada na Fig. B.2.6, será mostrada ao usuário avisando que o processo foi concluído.

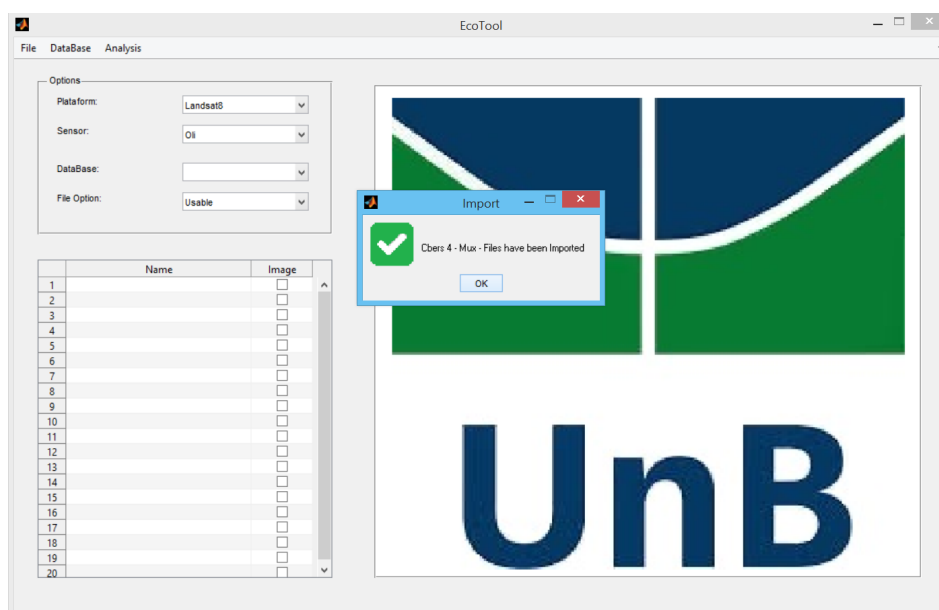


Figura B.2.6 – Carregando Concluído

B.3 Criação de Banco de Dados

Após importar dados ao projeto, é necessário criar pelo menos uma Banco de Dados ao projeto. O banco de dados se refere ao local onde se deseja monitorar. Por exemplo, caso seja importado dados do Distrito Federal ao projeto, e deseja-se monitorar a área do Gama, é preciso criar um banco de dados para a região do Gama.

Para criar um Banco de Dados vá na opção **DataBase** e clique em **New Data-Base** (Fig. B.3.1).

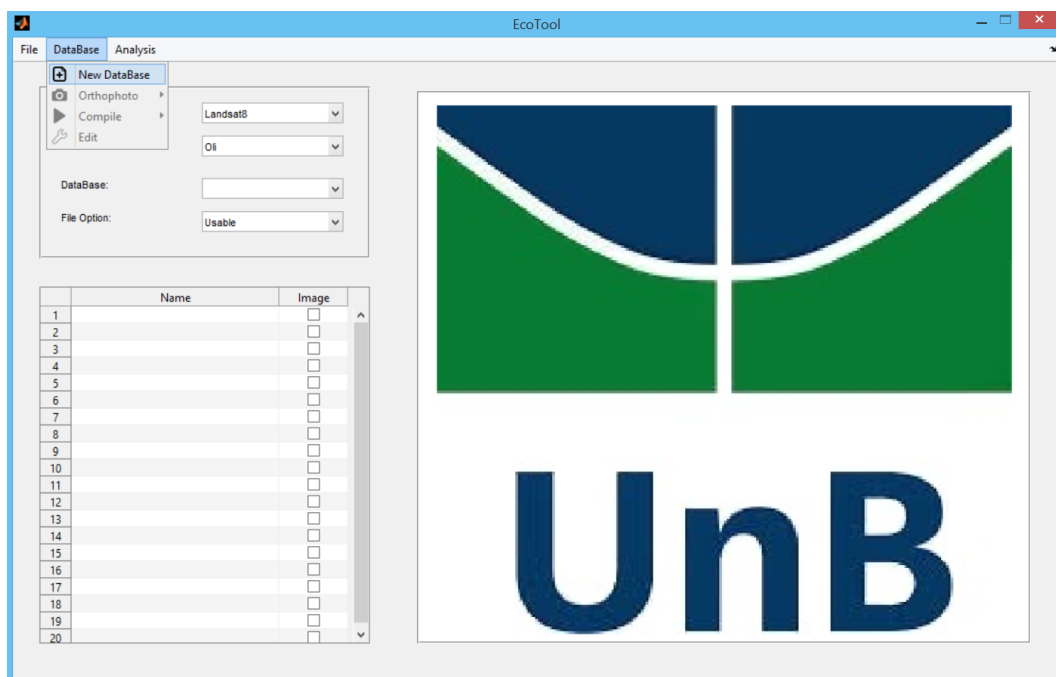


Figura B.3.1 – Criando Base de Dados

Depois, escolha um nome para o Banco de Dados e clique em **OK**. (Fig. B.3.2).

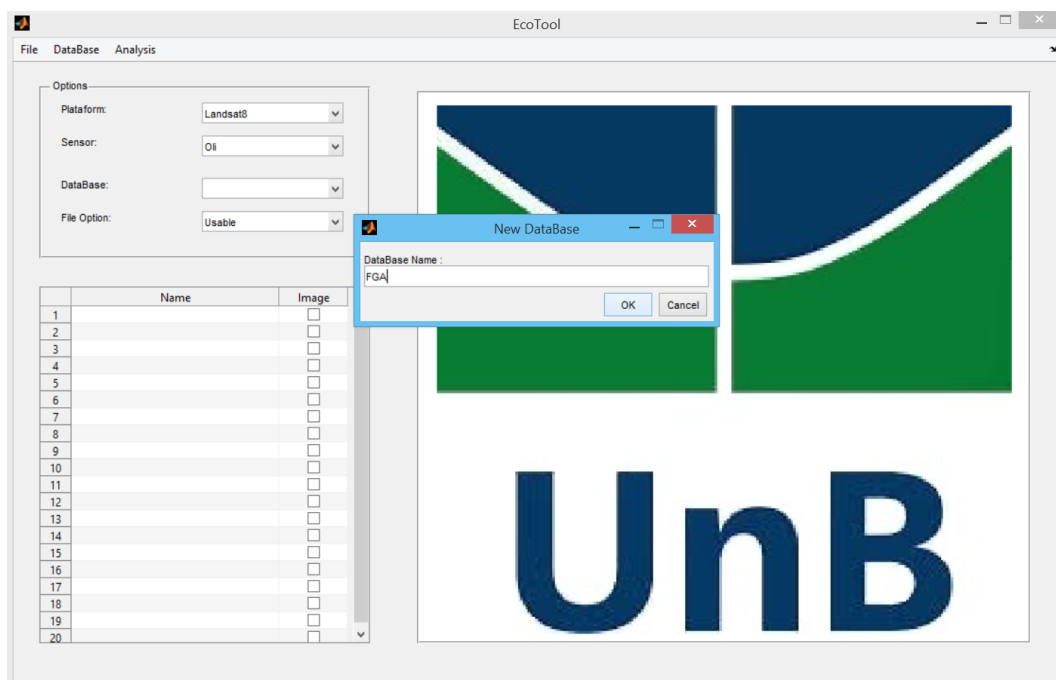


Figura B.3.2 – Nome Base de Dados

Após a criação do Banco de Dados, uma mensagem, ilustrada na Fig. B.3.3, será mostrada ao usuário avisando que o processo foi concluído.

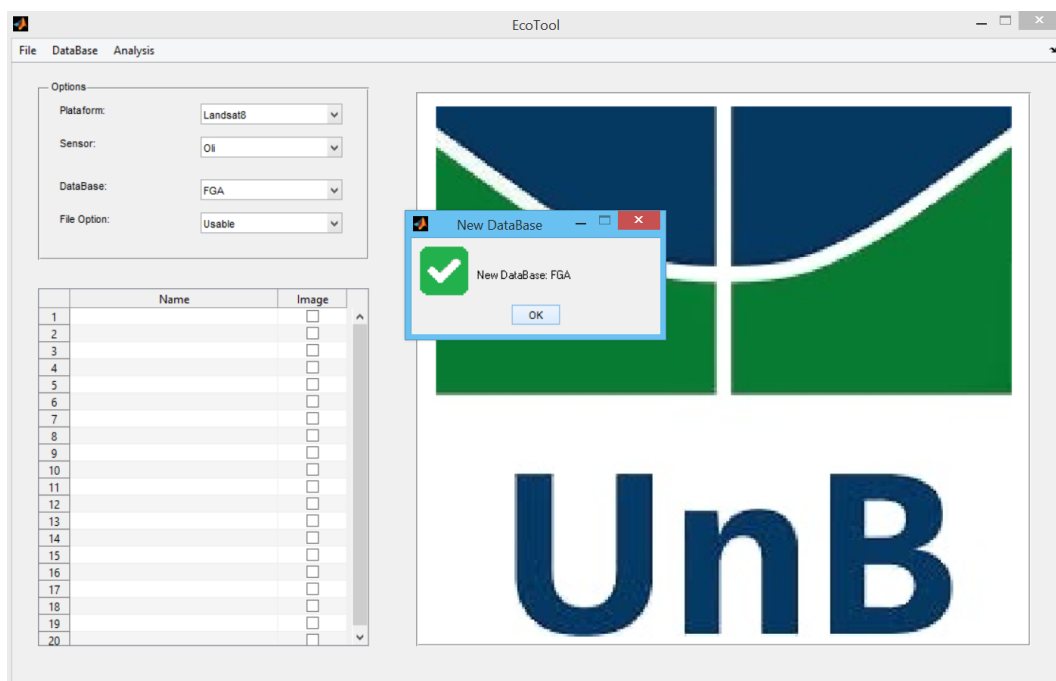


Figura B.3.3 – Base de Dados Criada

Lembrando que pode-se criar inúmeros Bancos de Dados para o mesmo projeto. Porém, é preciso que os bancos de dados estejam no perímetro das imagens carregadas ao projeto. Caso contrário, é necessário criar um outro projeto.

B.4 Seleção de Imagem de Referência - Ortofoto

Toda base de dados criada deve possuir pelo menos uma imagem de referência. É recomendado a utilização de uma imagem limpa, sem nuvens e sombras como imagem de referência. Para seleção de Ortofoto, vá na opção **DataBase, Orthophoto** e clique em **New Orthophoto** (Fig. B.4.1).

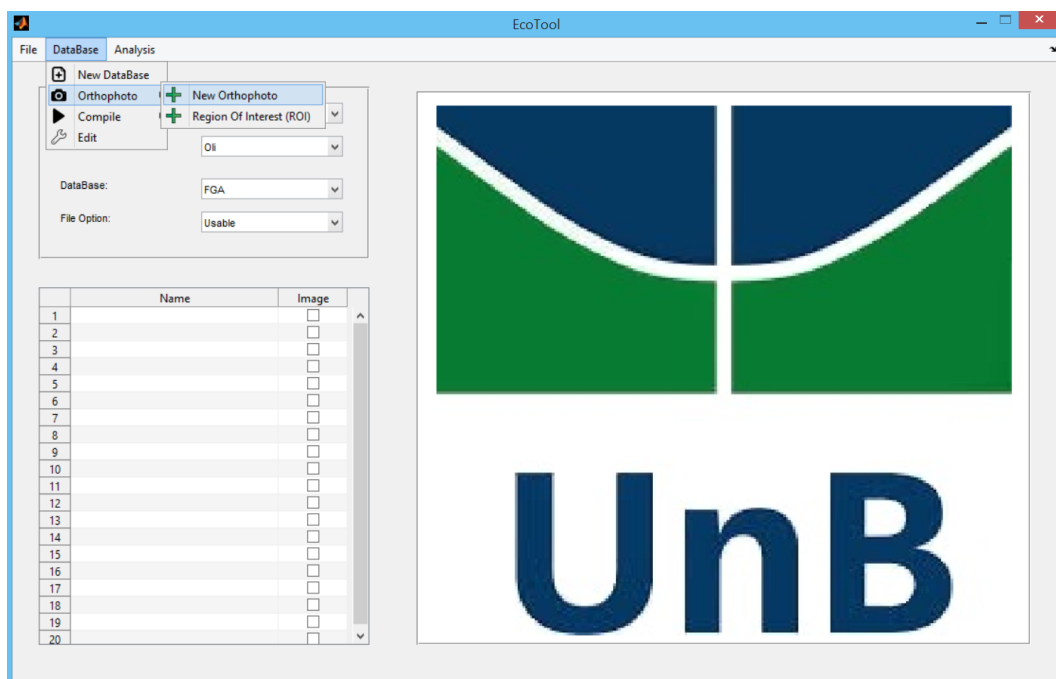


Figura B.4.1 – Seleção de Ortofoto

Uma nova interface aparecerá. Nessa interface, ilustrada na Fig. B.4.2, é possível fazer a seleção de ortofoto e visualizá-la.

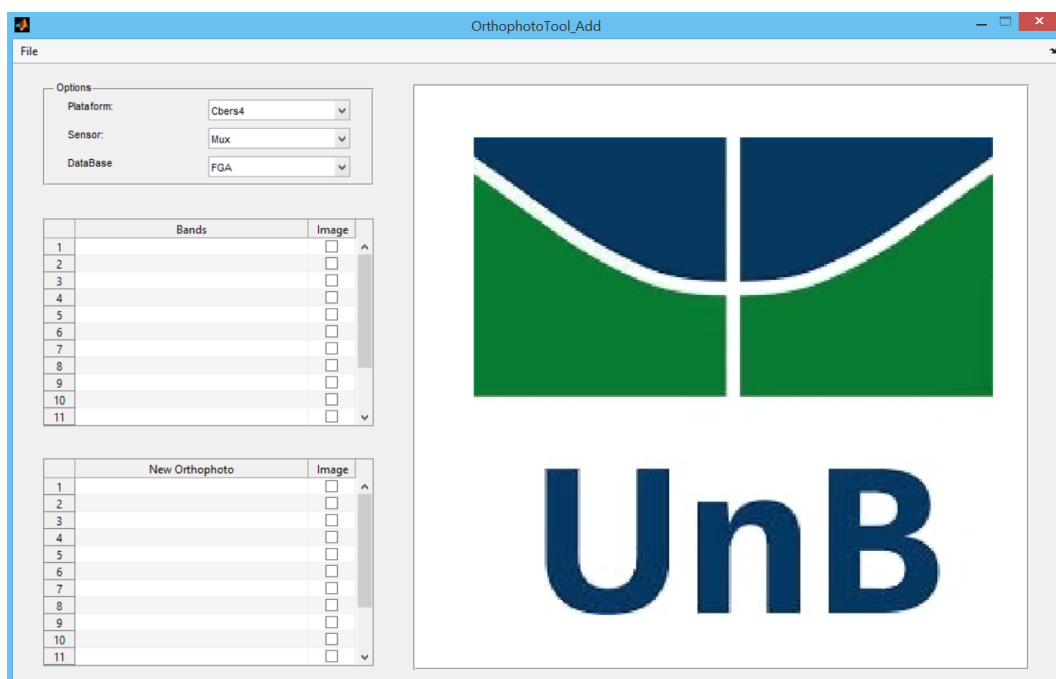


Figura B.4.2 – Interface para Seleção de Ortofoto

Primeiramente, selecione a Plataforma, o Sensor e Base de Dados no painel **Options** dessa nova interface. Depois, vá nas opções **File** e **Impot**, como ilustrado na Fig. B.4.3.

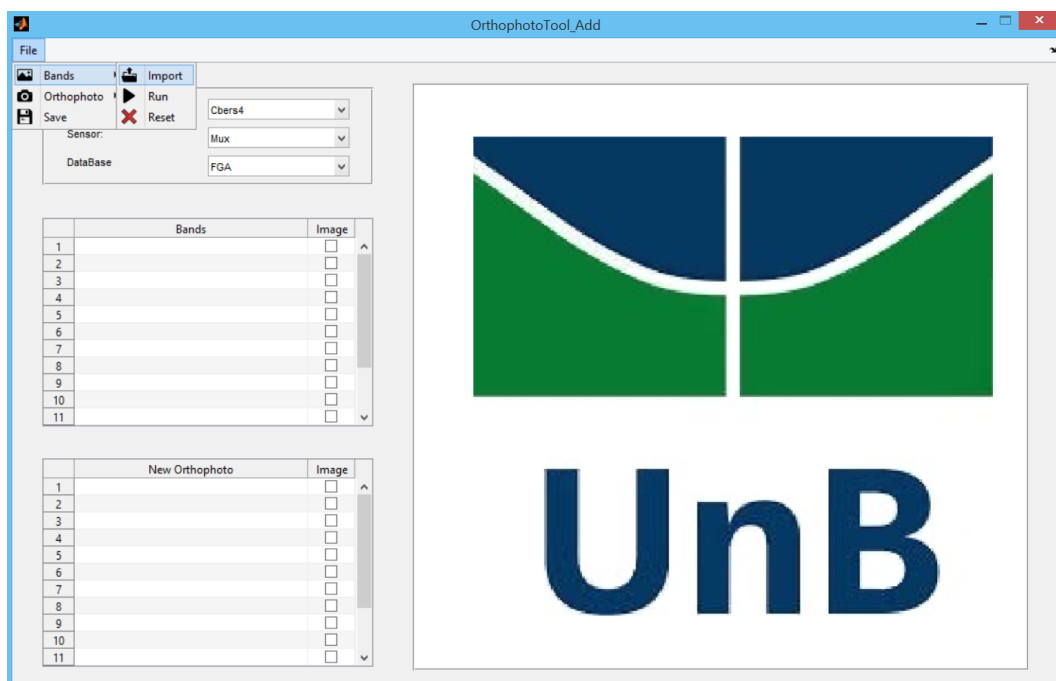


Figura B.4.3 – Importando Imagens - Passo 1

Por fim, como ilustrado na Fig. B.4.4, selecione todas as bandas espectrais da imagem de referência que se deseja utilizar e clique em **Open**.




Figura B.4.4 – Importando Imagens - Passo 2

No processo de carregamento da imagens, ilustrado na Fig. B.4.5, as imagens são georreferenciadas utilizando seus meta dados.

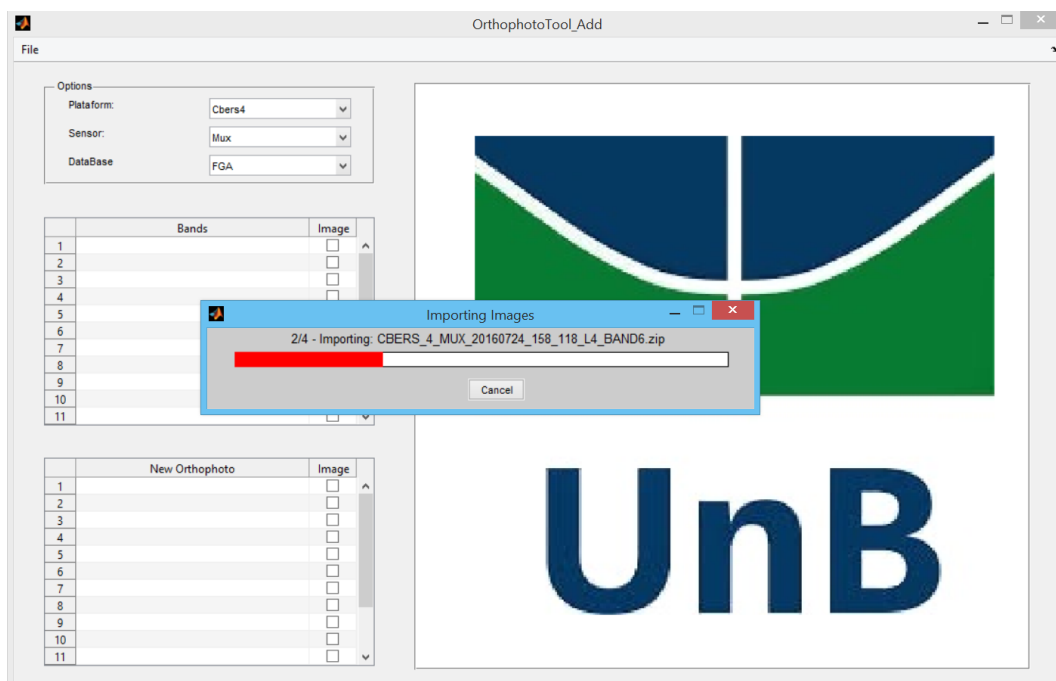


Figura B.4.5 – Importando Imagens

Após as bandas espectrais serem carregadas, e georreferenciadas, será possível visualizá-las, como mostra a Fig. B.4.6.

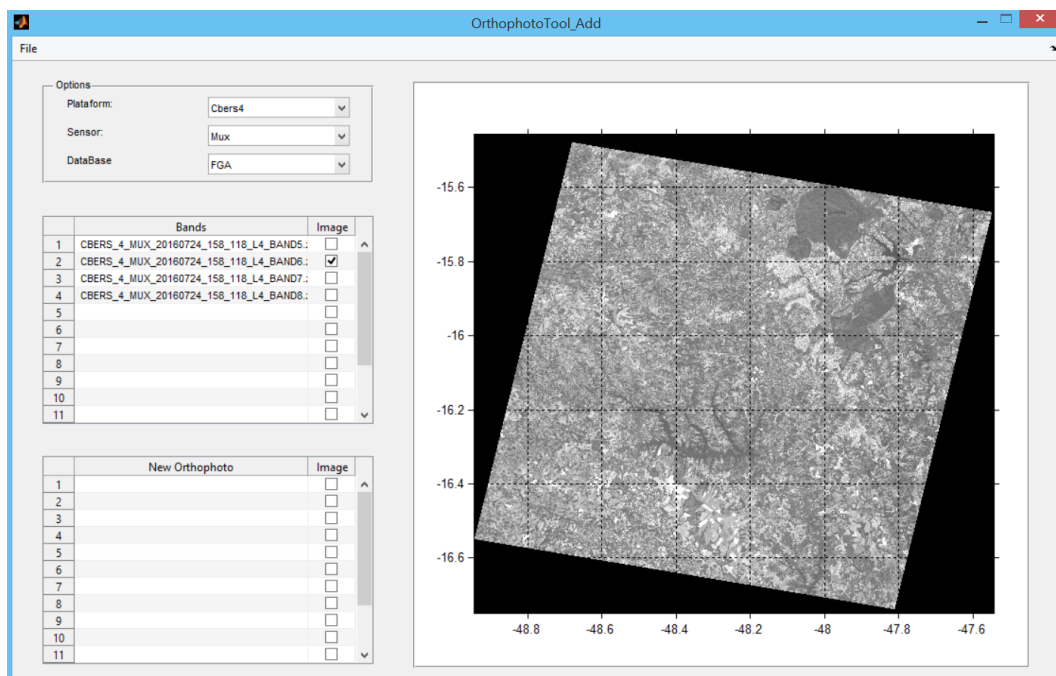


Figura B.4.6 – Imagens Carregadas

Agora é preciso escolher a área de interesse para a base de dados escolhida. Utilizando o exemplo da cidade do Gama, vamos selecionar a área da UnB/FGA. Primeiramente vá em **File**, **Bands** e **Run** (Fig. B.4.7).

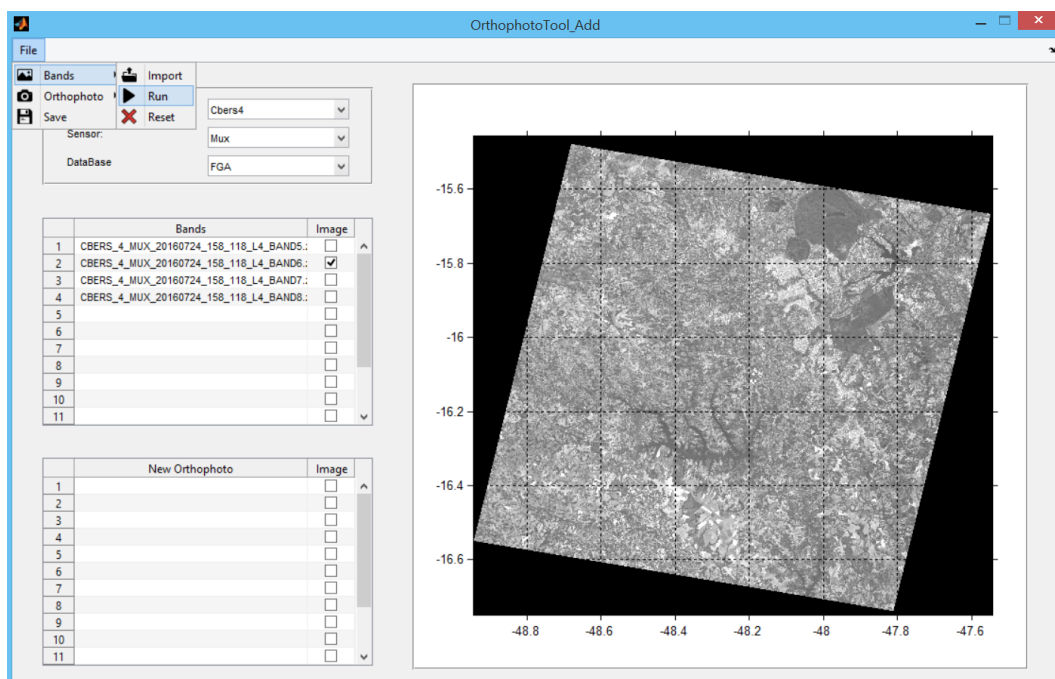


Figura B.4.7 – Área de Interesse - Passo 1

Selecione com o mouse (clitando com o botão esquerdo) a região desejada. Para finalizar o processo de seleção, clique com o botão direito e selecione a opção **Create Mask** (Fig. B.4.8).

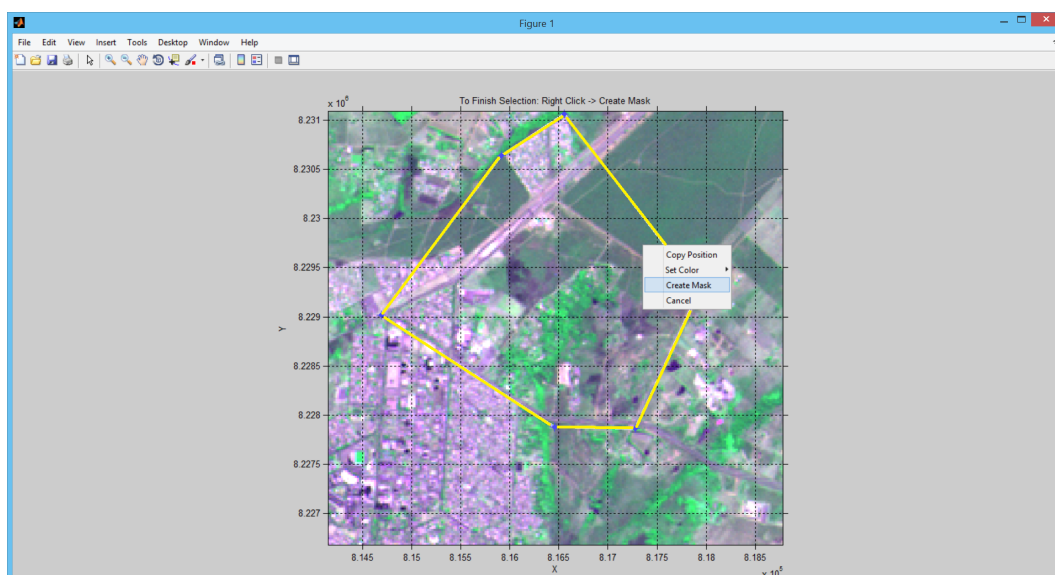


Figura B.4.8 – Área de Interesse - Passo 2

Após o processo de seleção ser concluído, será possível visualizar a região selecionada, como ilustra a Fig. B.4.9.

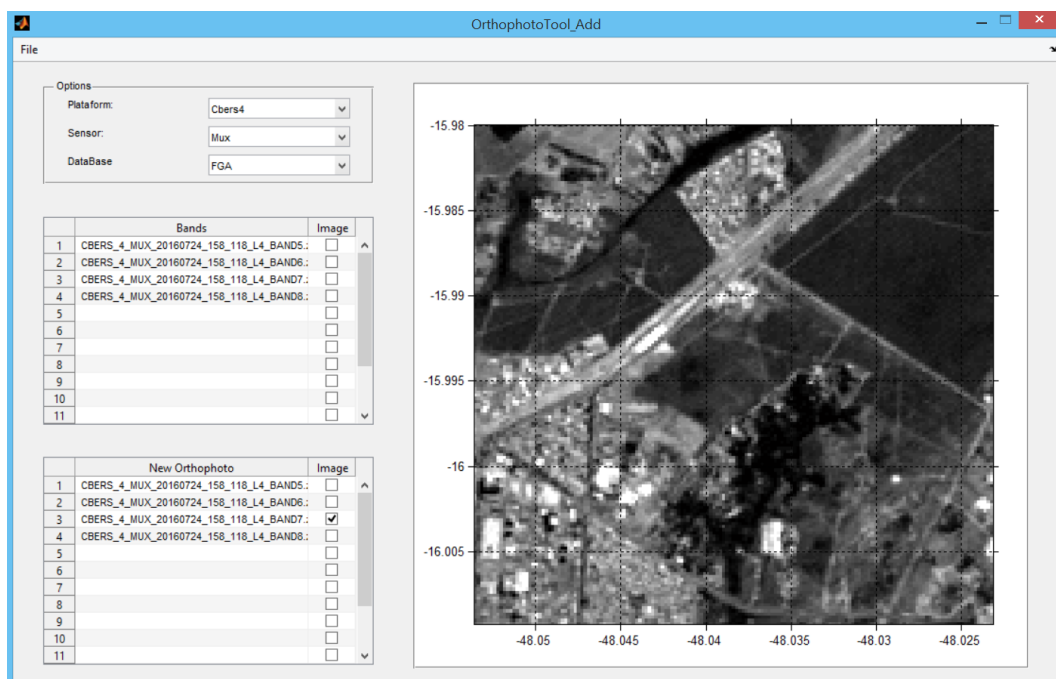


Figura B.4.9 – Visualizando a Área de Interesse

Por fim, salve o pacote de ortofotos por meio das opções **File** e **Save**, como ilustrado na Fig. B.4.10.

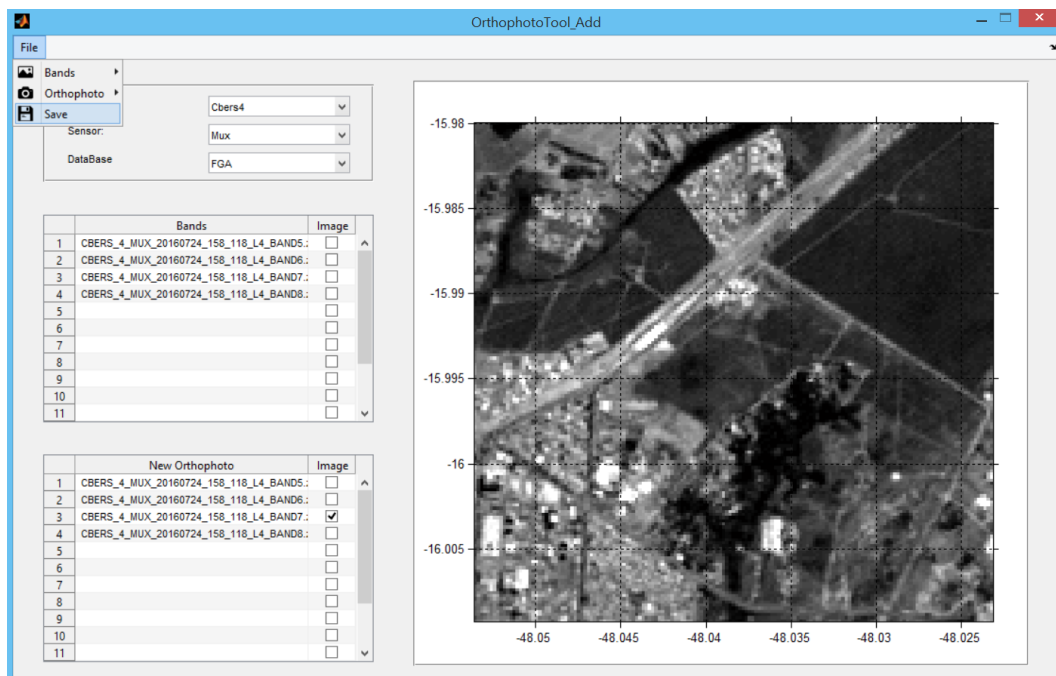


Figura B.4.10 – Salvando Pacote de Ortofotos

Uma caixa de diálogo aparecerá, ilustrado na Fig. B.4.11, pedindo para confirmar as seguintes opções: Plataforma, Sensor e Banco de Dados. Caso as informações estejam

corretas, clique em **Yes**, caso contrário, clique em **No**, modifique os parâmetros no painel **Options** e salve o pacote de ortofotos novamente.

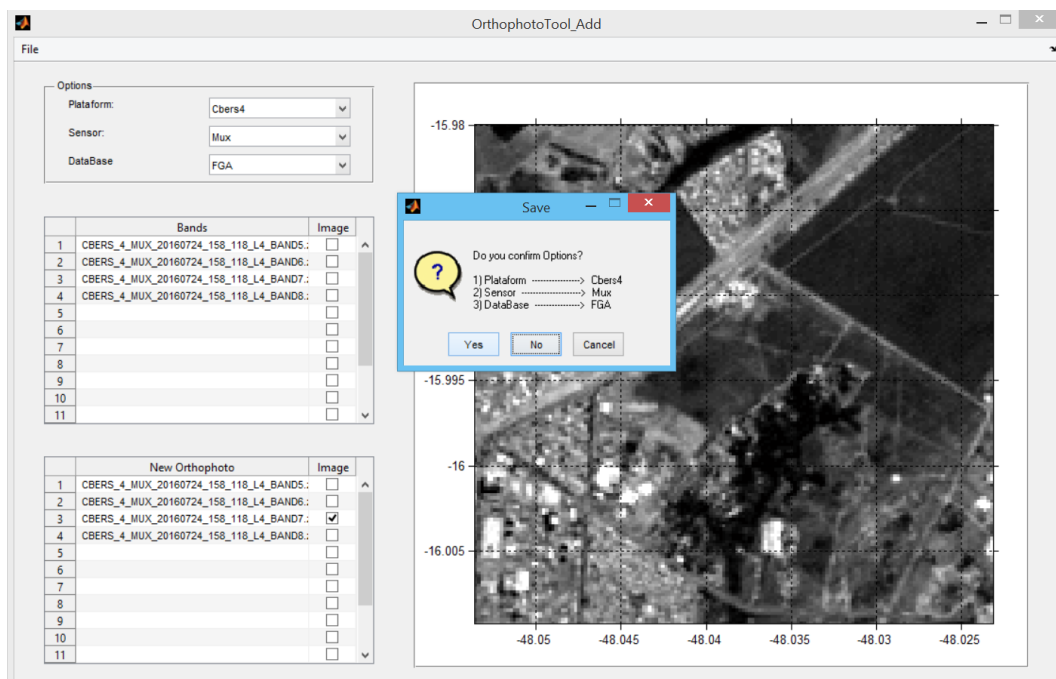


Figura B.4.11 – Confirmação para Salvar Pacote de Ortofotos

Fechando a interface de seleção de ortofoto e retornando para o programa principal, é possível observar a ortofoto adicionada ao projeto. Na opção **File Options**, selecione **Orthophoto**. Com isso, serão mostradas todas as Ortofotos adicionadas para a plataforma, sensor e banco de dados selecionados (Fig. B.4.12).

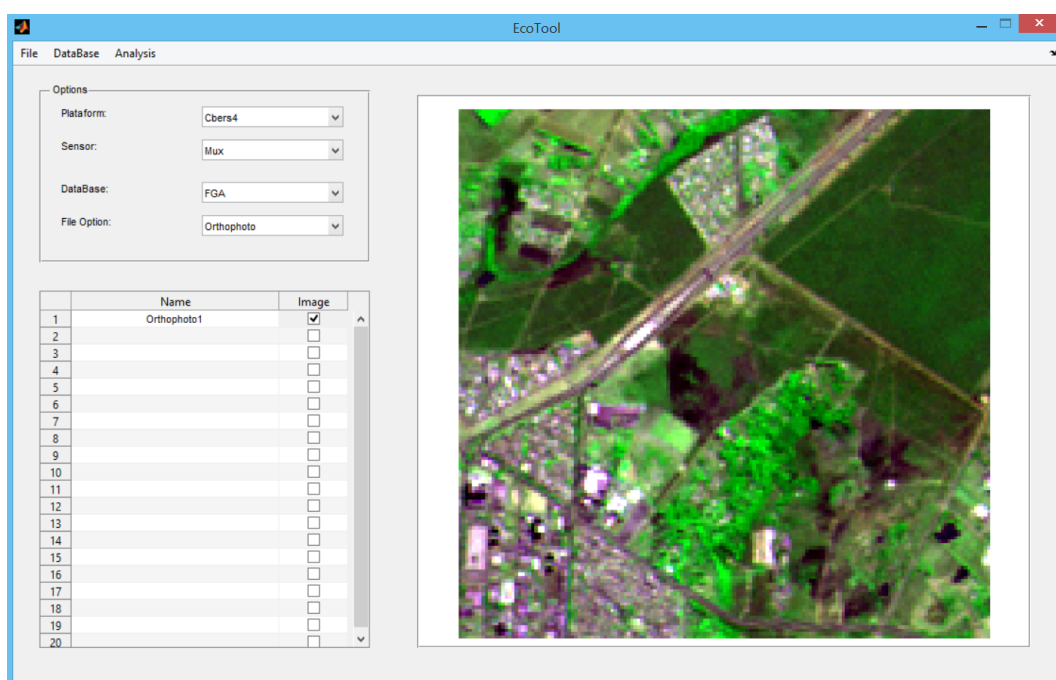


Figura B.4.12 – Ortofoto

B.5 Seleção de Região de Interesse - ROI

Caso não queira analisar toda a área pertencente a ortofoto, é necessário selecionar uma região de interesse (ROI, do inglês Region of Interest). O processo de seleção de ROI é feito pelas opções **File**, **Orthophoto** e **ROI** (Fig. B.5.1).

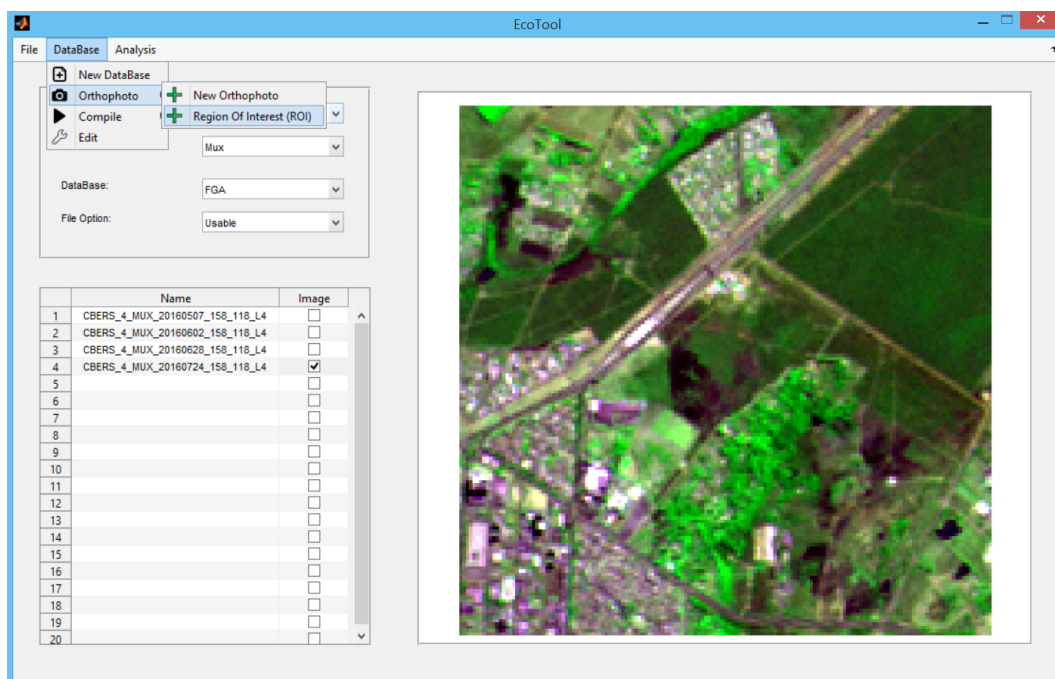


Figura B.5.1 – Ortofoto

Uma nova interface aparecerá. Nessa interface, ilustrada na Fig. B.5.2, é possível fazer a seleção da ROI.




Figura B.5.2 – Interface para Seleção de Região de Interesse

Para iniciar o processo de seleção de ROI, vá em **Import Orthophoto**. Selecione o Banco de Dados, a Plataforma e a Ortofoto como ilustrado nas figuras B.5.3, B.5.4 e B.5.5, respectivamente.

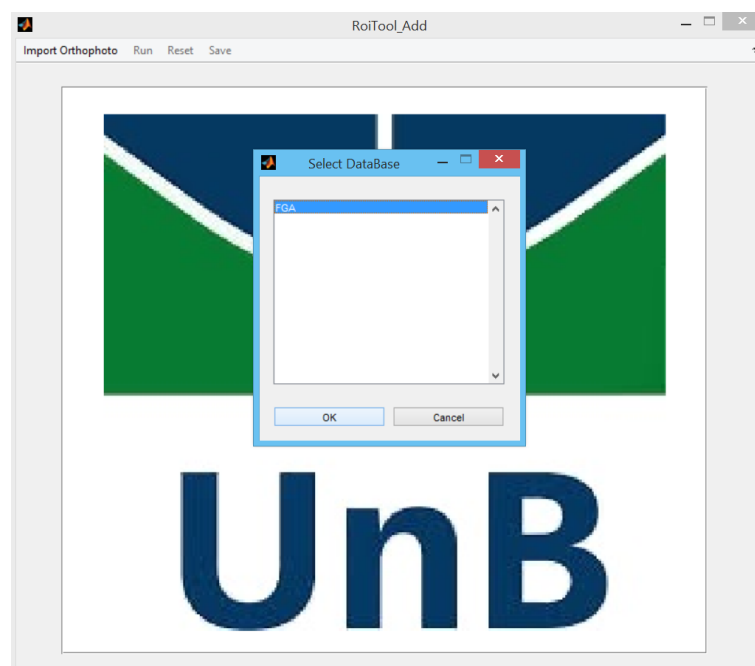


Figura B.5.3 – Banco de Dados




Figura B.5.4 – Plataforma

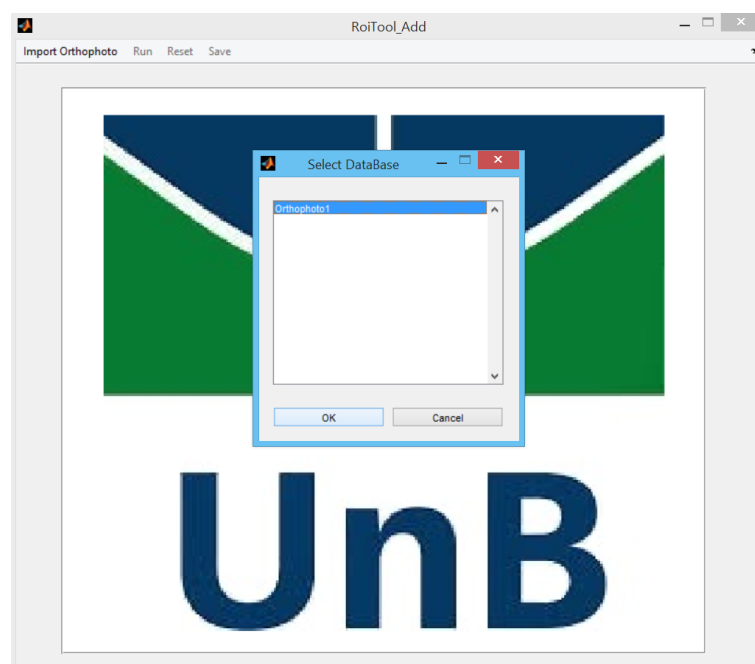


Figura B.5.5 – Ortofoto

Com todas as opções selecionadas, clique em **Run** e selecione a área de interesse com o mouse (figuras B.5.6 e B.5.7)

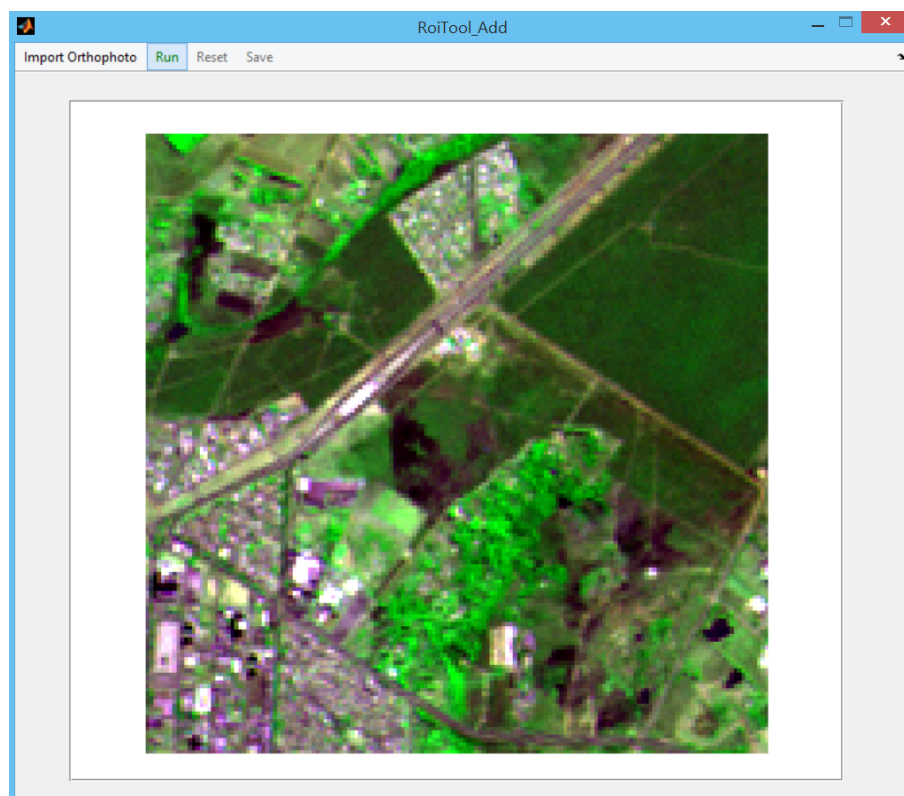


Figura B.5.6 – Run

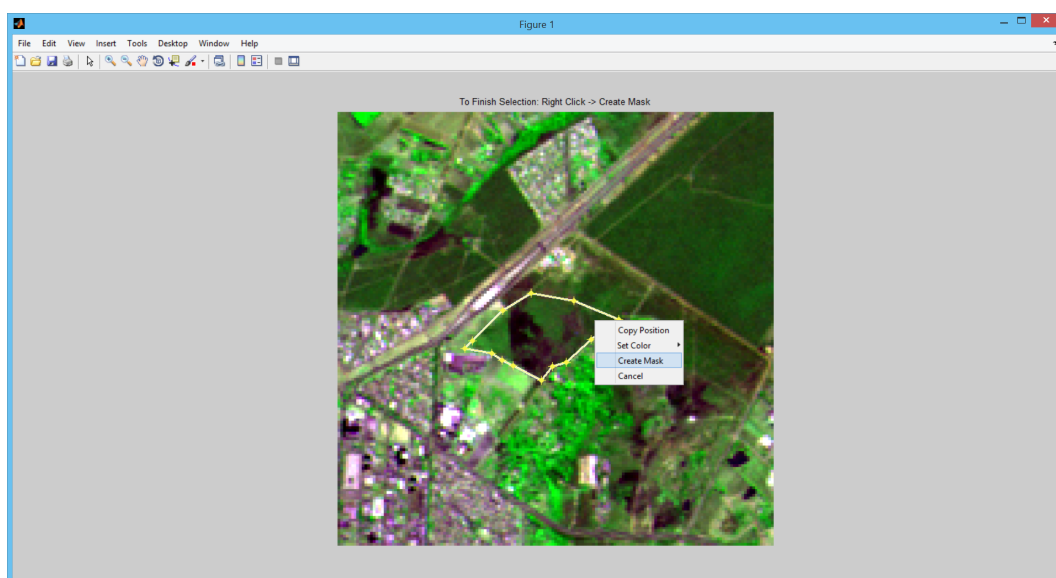


Figura B.5.7 – Seleção de área de interesse

Salve a ROI pela opção **Save** (Fig. B.5.8), confirme as informações que aparecerão na caixa de texto (Fig. B.5.9) e retorne ao programa inicial.




Figura B.5.8 – Salvando ROI




Figura B.5.9 – Confirmação de informações

B.6 Compilação das Imagens

Esse processo é o coração do software EcoTool. Nessa etapa, as imagens selecionadas serão descompactadas, georreferenciadas e analisadas para cada base de dados diferentes. Para isso, vá em **Project**, **Compile** e **Automatic**, como mostrado na Fig. B.6.1.

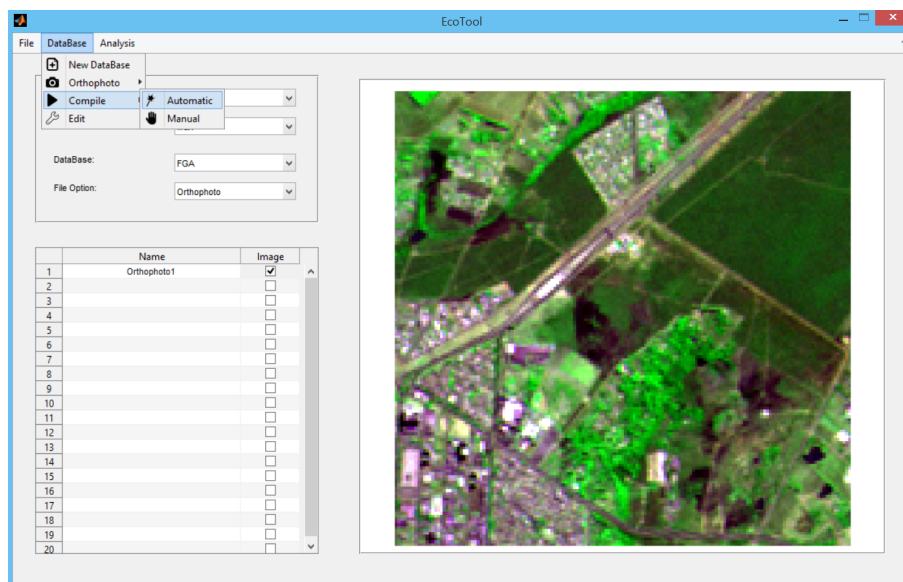


Figura B.6.1 – Compilação Automática das Imagens

Escolha o Banco de Dados (Fig. B.6.2), o Instrumento a ser compilado (Fig. B.6.3) e espere o processo ser finalizado (Fig. B.6.4).




Figura B.6.2 – Compilação Automática: Banco de Dados




Figura B.6.3 – Compilação Automática: Instrumento

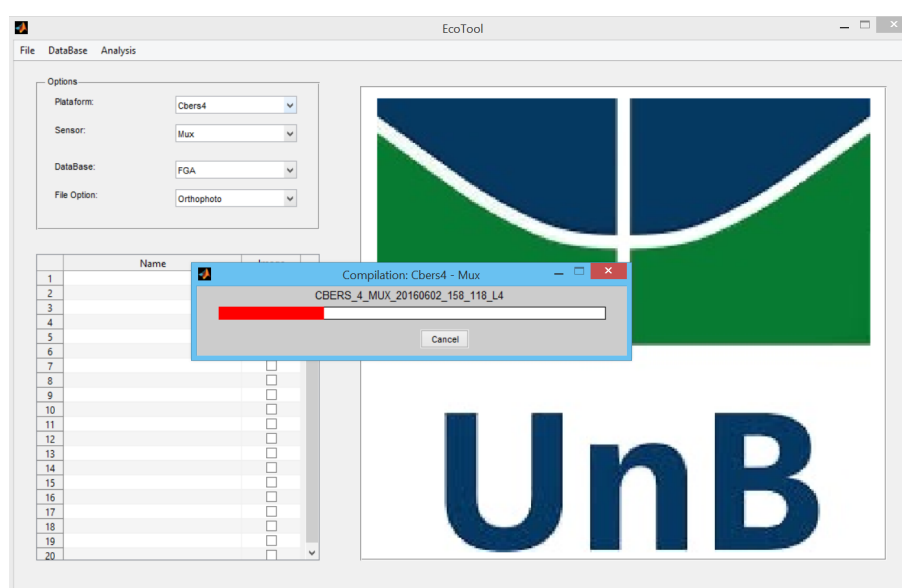


Figura B.6.4 – Compilação Automática: Barra de Acompanhamento

Ao final da compilação, as imagens aceitas pelo algoritmo automático poderão ser observadas no campo **Usable** da opção **File Options** (Fig. B.6.5). Já as imagens rejeitadas estarão no campo **Unusable**.

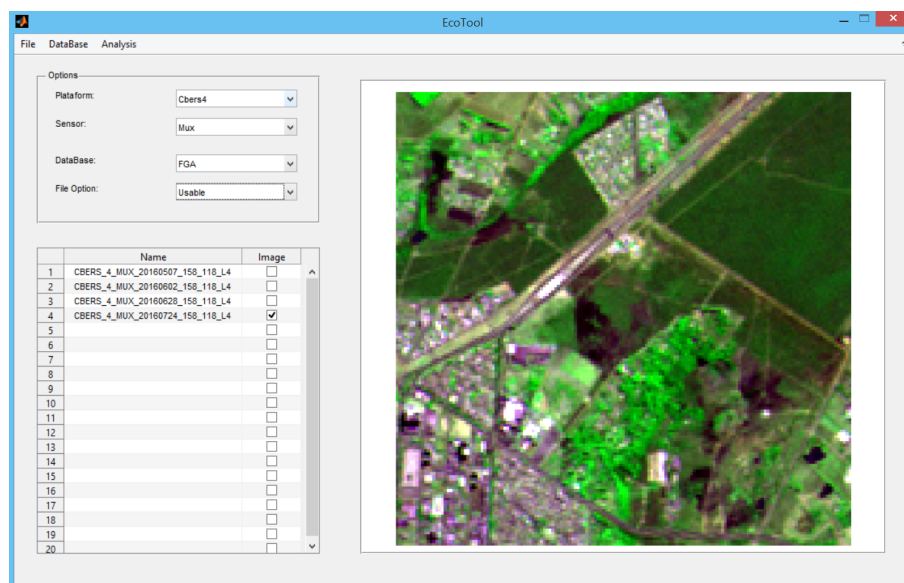


Figura B.6.5 – Imagens aceitas pelo algoritmo automático

B.7 Resultados

Nessa etapa os resultados são gerados. Primeiramente vá em **Analysis** e clique em **Compile**. Com isso, os resultados serão processados e poderão ser observados pelo campo **Results** da opção **Analisis** (Fig. B.7.1). Ao Clicar no campo **Results**, uma nova interface aparecerá, ilustrada na Fig. B.7.2.

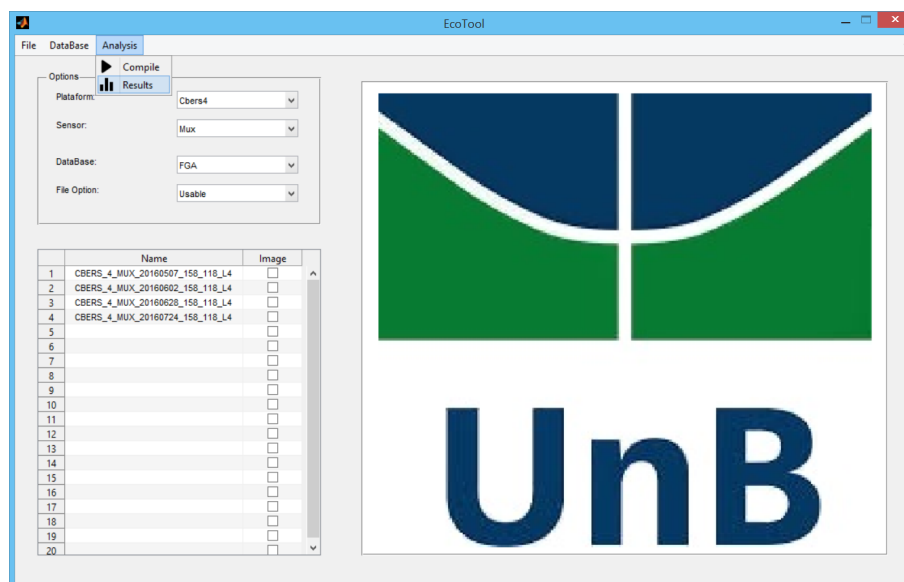


Figura B.7.1 – Resultados

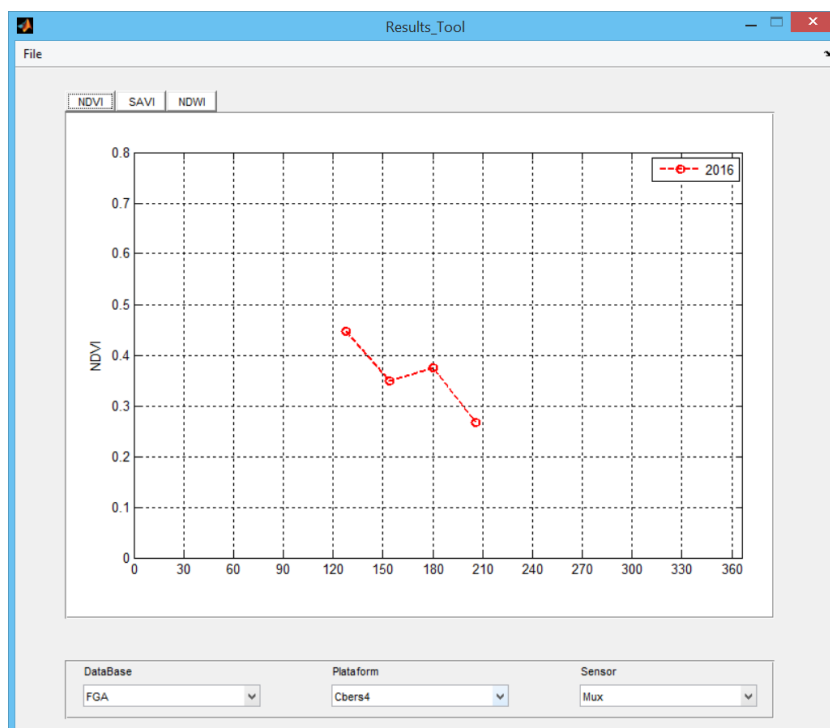


Figura B.7.2 – Interface de Resultados

Nessa nova interface, ilustrada na Fig. B.7.2, é possível observar o comportamento do NDVI, SAVI e NDWI ao longo dos anos. Além disso, também é possível exportar os resultados no formato “.txt”. Para exportar os resultados, clique em **File** e **Export**, como mostra a Fig. B.7.3.

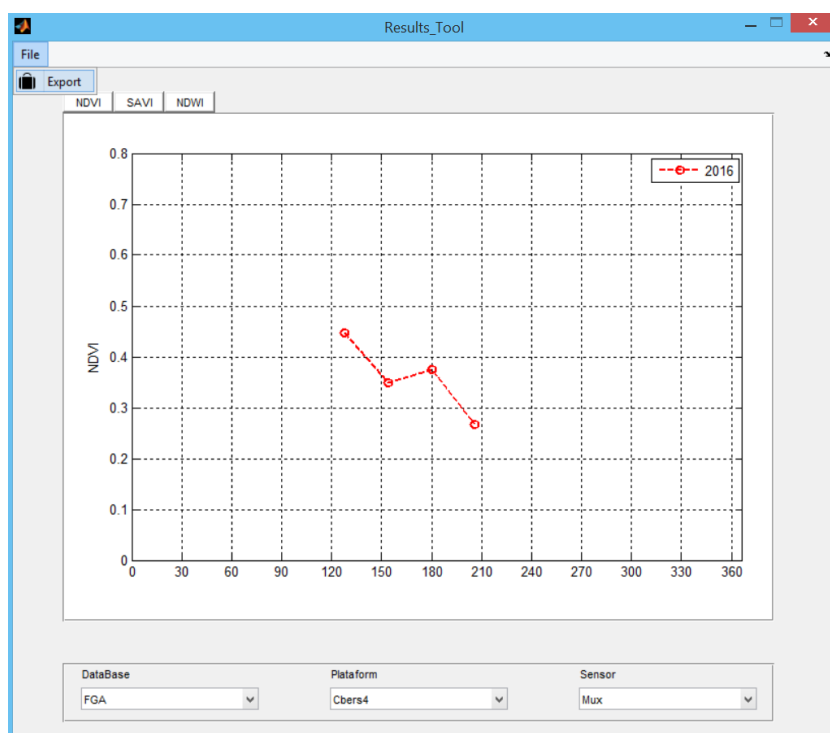


Figura B.7.3 – Interface de Resultados